



TEKNILLINEN TIEDEKUNTA

# **SUON VEDENPINNAN HAVAINNOINTI UAS- KUVAUKSEN AVULLA ENNALLISTAMISEN TUEKSI**

Lassi Päckilä

YMPÄRISTÖTEKNIikka

Diplomityö

Joulukuu 2020

Hanke on saanut rahoitusta Euroopan unionin LIFE-ohjelmasta. Aineiston sisältö heijastelee sen tekijöiden näkemyksiä, eikä Euroopan komissio tai EASME ole vastuussa aineiston sisältämien tietojen käytöstä.

Projektet har fått finansiering av Europeiska Unionens LIFE-program. Materialet reflekterar synsätt av upphovsmannen, och Europeiska kommissionen eller EASME är inte ansvariga för användning av materialets innehåll.

The project has received funding from the LIFE Programme of the European Union. The material reflects the views by the authors, and the European Commission or the EASME is not responsible for any use that may be made of the information it contains.



# TIIVISTELMÄ

Suon vedenpinnan havainnointi UAS-kuvauksen avulla ennallistamisen tueksi

Lassi Päckilä

Oulun yliopisto, ympäristötekniikan tutkinto-ohjelma

Diplomityö 2020, 102 s. + 5 liitettä

Työn ohjaajat yliopistolla:

Lauri Ikkala, tutkija/tohtorikoulutettava, Vesi-, energia- ja ympäristötekniikan tutkimusyksikkö

Meseret Menberu, tutkijatohtori, Vesi-, energia- ja ympäristötekniikan tutkimusyksikkö

Diplomityössä tutustutaan soiden monimuotoisuuteen, hydrologiaan, sekä niiden ennallistamisen taustoihin, tapoihin ja seurantaan Suomessa. Lisäksi kirjallisuuskatsauksessa tutustutaan lyhyesti UAS-kuvaukseen (engl. *Unmanned Aircraft System*), sen mahdollisuuksiin soiden vedenpinnan tason (WT, engl. *water table*) ja ennallistamisen seurannassa. Tutkimusosuudessa käsiteltiin Olvassuolla, Pohjois-Pohjanmaalla sijaitsevan Iso Leväniemen ennallistuskohteen WT:n mittausaineistoa mittauskaudelta ennen ennallistamista ja ennallistamisen jälkeen. Iso Leväniemen ennallistuskohde on 1970-luvulla ojitettu pohjavesiesiintymän reunalla sijaitseva, viettävä ja alun perin vahvasti pohjavesivaikutteinen avosuo. Lisäksi käsiteltiin lähellä ennallistuskohdetta, toisella puolella samaa pohjavesiesiintymää sijaitsevan Kirkaslammen luonnontilaisen vertailukohteen aineistoa samoilta mittauskausilta, ja kohteiden aineistoja verrattiin toisiinsa. Tutkimuksessa analysoitiin Ilmatieteen laitoksen tarjoamaa säädataa kohteille tulosten ja WT aineiston validoimiseksi. Ennallistamistoimien pääasiallisena tavoitteena soilla on palauttaa alkuperäinen vesitalous, johon kuivatusojitus on aiheuttanut häiriön. Tutkimusaineistojen vertailulla selvitettiin, ovatko ennallistamistoimet nostaneet suon WT:n luonnontilaisen kaltaiselle tasolle. Tutkimuskohteilla vedenpinnan korkeutta (WH, engl. *water height*) tallennettiin automaattisilla tiedonkeruulaitteilla, eli loggereilla.

Tilastollisen analyysin perusteella ennallistamistoimet nostivat WT:tä ennallistetulla suolla Iso Leväniemessä. WT nousi suon yläosan mittauspisteessä korkeammalle kuin luonnontilaisen Kirkaslammen suon vastaavassa pisteessä, kun ennallistetun suon

alaosassa WT jäi syvemmälle verraten Kirkaslammen suohon. Molemmissa mittauspisteissä Iso Leväniemessä vedenpinnan syvyys WTD (engl. *water table depth*) oli kuitenkin keskiarvoltaan ja mediaaniltaan ennallistamista seuraavana mittauskautena lähempänä luonnontilaisen Kirkaslammen suon WTD:tä, kuin ennallistamista edeltävänä mittauskautena. Keskihajonnan ja vaihteluvälin perusteella myös Iso Leväniemen suon vedenpinnan tason vaihtelu WTF pieneni ennallistamistoimien myötä. WTD:n aineiston virheeksi todettiin maastomittausten perusteella  $E \leq 10,4$  cm, joka voi soiden vesitaloutta tarkastellessa olla merkittävä. Todellinen suon vesitalouden palautumisen toteaminen vaatii pidempää hydrologista seuranta ja useampien muuttujien arviointia.

Tutkimusosuudessa interpoloitiin Iso Leväniemen suosta otettujen UAS-kuvien ja mittausaineiston avulla kaksiulotteinen WT:n profiili mittauspisteiden välille. Profiili interpoloitiin kaikille mittauskausien päiville. Analyysin perusteella WT nousi koko mittauspisteiden välisellä profiililla niin, että lähes koko profiili tulvi koko ennallistamista seuraavan mittauskauden. Interpoloitu WT vaikutti käyttäytyvän luonnollisella tavalla, mutta validointiaineiston puuttuessa sen todenmukaisuuden todentaminen jäi uupumaan. Maastohavaintojen perusteella koko profiilin tulvimisen ei arvioitu olevan mahdollista. Interpolointikokeilu onnistui kuitenkin niin hyvin, että menetelmäkehitystä on syytä jatkaa. Jos löydetään hyvä, yleistettävä interpolointitapa, voi tulevaisuudessa olla mahdollista tuottaa interpoloituja WT:n pintamalleja pistemäisistä WT:n monitorointiaineistoista erilaisille suokohteille, tai jopa ekstrapoloida malli kokonaiselle kohteelle käyttäen hyväksi yksittäistä pistemäistä aineistoa.

*Asiasanat: UAS, soiden ennallistaminen, WT, WTD, veden pinnantaso*



# ABSTRACT

UAS-monitoring of peatland water table for restorative purposes

Lassi Pääkkilä

University of Oulu, Degree Programme of Environmental Engineering

Master's thesis 2020, 102 pp. + 5 Appendixes

Supervisors at the university:

Lauri Ikkala, researcher/PhD candidate, Water, energy and environmental engineering research unit

Meseret Menberu, postdoctoral researcher, Water, energy and environmental engineering research unit

This diploma thesis reviews peatland diversity and hydrology in Finland, and peatland restoration backgrounds, methods and monitoring. In addition, UAS (Unmanned Aerial System) -photogrammetry and its applications in restoration monitoring are revised. In the research part of the thesis Iso Leväniemi peatland restoration site water height logger data was treated and analyzed for two measurement seasons, one before and one after restorative actions. Iso Leväniemi restoration site in Olvassuo nature reserve, Northern Ostrobothnia, Finland is a sloped open fen located next to a large aquifer and is strongly fed by this aquifer. Water table level (WT) was recorded in the site via two automatic water height loggers with capacitive sensors. Also, data from two additional water level loggers located on the opposite side of the same aquifer, in Kirkaslampi pristine peatland site, was treated, analyzed and used for reference. Precipitation and temperature data for the sites were analyzed to validate logger data and the obtained results. Restoration site's data before restoration was compared to the data after restoration to find out how restoration actions impacted on water table depth (WTD) and water table fluctuation (WTF) on site. Since the main peatland restoration goal is to recover natural water economy, Iso Leväniemi site data was compared to the Kirkaslampi pristine site data to find out if natural state of WTD has been achieved.

According to statistical analysis WT rose due to restoration actions in Iso Leväniemi restoration site. WT actually rose significantly higher than in Kirkaslampi pristine site in the upper part of the peatland, but in the lower part of the restoration site WT stayed

significantly below pristine reference site WT. Generally, WT was closer to the pristine reference in both measurement points after restoration actions. According to the standard deviation and range also WTF was more restrained in the measurement season following restoration actions. WTD error was  $E \leq 10,4$  cm which can be significant. It is also noted that to find out true significance and validate the success of restoration actions in terms of hydrology, a longer monitoring period and analysis of more variables are needed.

In the second part of the study, a two-dimensional WT profile was interpolated from monitoring data and UAS aerial photos taken from Iso Leväniemi restoration site. The profile was calculated between the measurement points for every day of both measurement seasons. According to analysis WT rose throughout the whole profile due to restoration actions so that the whole profile flooded for the whole measurement season following the actions. Interpolated WT profile seemed to act in a realistic way at least partially, but because of lacking additional WTD data validation was not done for the profile. Still, interpolation experiment seemed promising and method development should be continued. If a proper method for interpolation is found it is possible to interpolate or even extrapolate WT surfaces using UAS data for complete restoration areas and ease the work of restoration monitoring.

*Keywords: UAS, peatland restoration, WT, WTD, water table*

# ALKUSANAT

Tutkimuksen tavoitteena on tutustua soiden ennallistamisen taustoihin, ojituksen ja ennallistamisen vaikutuksiin erityisesti hydrologian kannalta, sekä ennallistamisen monitorointiin. Soiden ennallistaminen on tärkeä keino biodiversiteetin säilyttämisessä ja vesistöjen suojelussa. Luonnontilaiset suot ovat myös tärkeä pitkäaikainen hiilen varasto, ja siten ennallistaminen voi osaltaan hillitä ilmastonmuutosta. Tutkimusosuudessa analysoidaan kahden suokohteen vedenpinnan tason mittausaineistoa ja sovelletaan *Unmanned Aircraft System* (UAS) -kuvauksen, tuttavallisemmin dronekuvauksen mahdollisuuksia vedenpinnan tason mallintamiseen soilla. Tutkimuksen UAS-kuvauksen suoritti yhteistyössä Itä-Suomen yliopisto. Työn ohjaaja Lauri Ikkala teki UAS-kuvien käsittelyn tutkimuskohteilta, ja yhdessä työn toisen ohjaajan Meseret Menberun kanssa auttoi hyvien mittausaineiston käsittelytapojen löytämisessä.

Työ toteutettiin toukokuun ja joulukuun 2020 välisenä aikana. Kiitos Oulun yliopiston Vesi-, energia- ja ympäristötekniikan tutkimusryhmälle mahdollisuudesta syventyä kiinnostavaan tutkimukseen. Erityisesti haluan kiittää ohjaajiani Lauri Ikkalaa ja Meseret Menberua sekä valvojiani Anna-Kaisa Ronkasta ja Hannu Marttilaa alasta ja aiheesta ja avusta ja neuvoista. Kiitän myös Maa- ja vesitekniikan tuki ry:tä apurahasta diplomityön kirjoittamiseen. Kiitos Itä-Suomen yliopistolle ilmakuvista. Kiitos Metsähallituksen Miia Kokkonen, Maarit Similä, Christian Koivula, Santtu Kareksela, Sakari Rehell ja Mikko Heikura tutkimusaineistosta ja avusta, ja kiitos kaikille Metsähallituksen tekijöille ilmakuvista, tutkimuksen aineistosta, sekä erityisesti arvokkaasta työstä. Kiitos myös ystäväilleni ja perheelleni neuvoista ja tuesta matkalla kohti valmistumista.

Oulussa, 6.12.2020



Lassi Pääkkilä

# SISÄLLYSLUETTELO

TIIVISTELMÄ

ABSTRACT

ALKUSANAT

SISÄLLYSLUETTELO

MERKINNÄT JA LYHENTEET

1 JOHDANTO .....	10
2 KIRJALLISUUSKATSAUS .....	12
2.1 Suoluonto Suomessa .....	12
2.2 Suot hiilen ja veden varastona .....	19
2.3 Suoluonnon uhanalaisuus .....	22
2.4 Soiden ojituksen seuraukset .....	25
2.5 Soiden ennallistaminen .....	31
2.6 UAS .....	38
2.7 Interpolointi .....	45
3 TUTKIMUS .....	48
3.1 Kohteet .....	49
3.2 Vedenpinnan tason seuranta .....	55
3.3 Mittausaineiston käsittely .....	57
3.4 Sadehavainnot .....	61
3.5 Korkeusmalli .....	62
3.6 WT:n interpolaatio .....	64
3.7 Tulokset .....	65
4 TULOSTEN TARKASTELU .....	76
4.1 Suon vedenpinnan vaihtelu .....	76
4.2 WT:n interpolaatio .....	77
4.3 Virhelähteet ja epävarmuudet mittauksissa .....	79
4.4 Johtopäätökset ja suositukset .....	80
4.5 Yhteenveto .....	83

LÄHDELUETTELO

LIITEET:

Liite 1. WT:n interpolaation R-koodi Olvassuo\_interpolation.R

Liite 2. Loggerin 101 aineiston käsittelyn R-koodi data plotter 101.R

Liite 3. Loggerin 102 aineiston käsittelyn R-koodi data plotter 102.R

Liite 4. Loggerin 103 aineiston käsittelyn R-koodi data plotter 103.R

Liite 5. Loggerin 104 aineiston käsittelyn R-koodi data plotter 104.R

## MERKINNÄT JA LYHENTEET

$\Delta$	Vaihteluväli, [cm]
$\Delta WT$	Pohjaveden pinnan muutos, [mm]
$\mu$	Aritmeettinen keskiarvo, [cm]
$\sigma$	Keskihajonta, [cm]
$\psi$	Matrikpotentiaali, [mm]
ACE	<i>Action Communautaire pour l'Environnement</i>
E	Virhe
$F_R$	Kameran todellinen polttoväli [mm]
GSD	<i>Ground Sampling Distance</i> , kuvan haluttu tarkkuus eli vierekkäisten pikselien keskikohtien etäisyys [cm/pikseli]
H	Lentokorkeus [m]
K	Hydraulinen johtavuus, vedenjohtavuus, [m/s]
RMSE	<i>Root Mean Squared Error</i> , keskineliövirheen neliöjuuri
$S_w$	Kameran kuvakennon todellinen leveys [mm]
$S_y$	Ominaissaanto
SAC	<i>Special Area of Conservation</i>
SCI	<i>Site of Community Importance</i>
SfM	<i>Structure from Motion</i>
SG	<i>Storage gain</i> , varaston muutos
SPA	<i>Special Protection Area</i>
UAS	<i>Unmanned Aircraft System</i>
UAV	<i>Unmanned Aerial Vehicle</i>
WH	<i>Water height</i> , vedenpinnan korkeus [mm]
WT	<i>Water table</i> , vedenpinnan taso [m]
WTD	<i>Water table depth</i> , vedenpinnan syvyys [cm]
WTF	<i>Water table fluctuation</i> , pohjavedenpinnan vaihtelu, [mm]
imW	Kuvan leveys pikseleissä [pikseliä]
n	Huokoisuus

# 1 JOHDANTO

Suomessa soita on ojitettu suuressa mittakaavassa erityisesti metsätalouden tarpeisiin. Parina viime vuosikymmenenä on herätty ojituksen aiheuttamiin vesistökuormiin ja biodiversiteettikatoon, jota esimerkiksi tehometsätalous osaltaan on kiihdyttämässä. Metsätalouden tukinuiton tarpeisiin virtavesiä on perattu läpi Suomen ja jättömaana näyttäytyneen suoluonnon ojituksella metsien kasvua pyritty parantamaan. Ojituksen ja ennallistamisen vaikutuksia on tutkittu ympäri maailman enenevissä määrin, ja niin myös Suomessa. Ojituksella ei ole päästy riittävään puunkasvuvauhtiin erityisesti karuilla ja märillä soilla niin, että hyödyt ylittäisivät haitat. Muun muassa ojituksen myötä useat suoluontotyypit, erityisesti rehevät ja puustoiset suot ovat varsinkin Etelä-Suomessa käyneet uhanalaisiksi (Kaakinen et al. 2018b). Samoin ovat uhanalaistuneet kosteikkojen lintulajit, joiden suosimat mätät ja laajat suoalueet ovat vähentyneet maassamme ojituksen ja maankäytön myötä (Ojanen 2020).

Ekosysteemien ennallistaminen on keino pyrkimyksissä biodiversiteetin säilyttämiseen ja maankäytön vaikutuksien lieventämiseen. Tässä työssä tutustutaan suomalaisten soiden tilaan ja hydrologiaan, ojituksen vaikutuksiin soilla, ennallistamisen periaatteeseen ja menetelmiin suoluonnossa sekä ennallistamisen seurantaan. Soiden ennallistamisen seurauksia on tutkittu paljon, ja ristiriitaisiakin tuloksia on saatu, ehkäpä niiden monimuotoisuuden takia. Suo ei ole luontotyyppinä yksiselitteinen ja suot vaihtelevatkin paljon esimerkiksi ilmaston seurauksena. Soita tulisi tarkastella aina osana ympäristöään, sillä ympäristön maankäyttö vaikuttaa niiden vesitalouteen ja siten suolla menestyviin lajeihin. Soilla erityisesti veden laatu, sen pinnan syvyys (WTD, engl. *water table depth*) ja pinnan vaihtelu (WTF, engl. *water table fluctuation*) määrittävät esiintyviä kasvilajeja, niiden mahdollisuuksia, ja siten myös suon hiilensidontakykyä. Ojituksen tarkoituksena on laskea vedenpinnan tasoa (WT, engl. *water table*) niin, että sukkessio kohti kangasmaisempaa ekosysteemiä alkaa ja puun tuotto alueella paranee. Ennallistamisen pääasiallinen tavoite ojitettujen soiden tapauksessa onkin ojat tukkimalla nostaa WT luonnontilaista vastaavalle tasolle, ja siten palauttaa vesitalous ennallistettavalla kohteella ja ohjata valuma-alueen vesitaloutta kohti luonnonmukaista.

Työn tutkimusosuudessa käsitellään Metsähallituksen ennallistuskohteen ja luonnontilaisen vertailukohteen vedenpinnan korkeuden (WH, engl. *water height*) mittausaineistoa, ja tilastollisen analyysin avulla selvitetään kuinka WT on muuttunut ennallistamistoimien myötä ja ovatko ne onnistuneet nostamaan WT:n luonnontilaisen

kaltaiselle tasolle. Hypoteesi on, että WT on noussut ennallistuskohteen mittauspisteillä. Kohteilla WH:ta mitattiin automaattisilla tiedonkeruulaitteilla, eli loggereilla, jotka tuottavat pistemäistä tietoa vedenpinnan korkeudesta läpi mittauskauden. Loggerit mittasivat WH:ta kapasitiivisten sensorien avulla, joiden toiminta perustuu ympäröivän väliaineen kapasitanssin muutokseen. Loggerien tuottama aineisto on usein ajallisesti kattavaa mittauskaudellaan, mutta antaa vain suppean kuvan koko suon WT:stä ja virtauksista spatiaalisen rajoittuneisuutensa vuoksi. Samalle kohteelle sijoitetulla useammalla loggerilla voidaan tehdä arvioita koko suon vesitaloudesta. Loggerit vaativat kuitenkin aina loggerikaivon, ja loggerin tuottamat mittaukset on syytä tarkastaa mittauskauden aikana tehtävillä käsimittauksilla. Suot ovat usein vaikeakulkuisia ja jopa vaarallisia kulkijalle, joten uudenaikaiset UAS (engl. *Unmanned Aircraft System*) - kaukokartoitusmenetelmät voisivat tarjota mahdollisuuden ennallistamisen helpompaan, kattavampaan ja objektiivisempaan seurantaan pistemäisten loggerien ohelle.

Kirjallisuuskatsauksen loppupuolella käydään läpi uudenaikaisen UAS-kuvaustekniikan periaatteita ja niiden mahdollisuuksia suon WT:n seurannassa. UAS-tekniikka eli kansankielisemmin drone-tekniikka on yleistynyt vauhdilla viime vuosina, ja sitä on alettu hyödyntää myös ympäristötieteiden saralla esimerkiksi kaukokartoituksessa ja tilanteissa, joissa näytteitä on saatava vaikeasti tavoitettavista tai vaarallisista paikoista. Tutkimuksessa tuotetaan ennallistuskohdeelta otettujen UAS-kuvien avulla profiili suon pinnasta kahden automaattisen loggerin ja kuvista tunnistettujen avovesipisteiden välille, ja mallinnetaan interpoloimalla WT koko leikkaukselle molempien mittauskausien kaikille päiville. Tavoitteena on kehittää menetelmää, jonka avulla voitaisiin mallintaa WT koko ennallistettavan suon alueelle ennallistustoimien vaikutusten laajemmaksi ymmärtämiseksi ja ennallistamisen seurannan helpottamiseksi. UAS-menetelmän kehitys on rajoitettu kaksiulotteisen profiilin WT:n mallintamiseen, josta menetelmäkehitystä voidaan jatkaa tulevaisuudessa. Tuotettua WTD-aineistoa profiilille analysoidaan tilastollisin keinoin. Hypoteesina analyysissä on, että WT on noussut ennallistamistoimien myötä koko tuotetulla profiililla.

## 2 KIRJALLISUUSKATSAUS

### 2.1 Suoluonto Suomessa

Suot ovat tärkeä ja erottamaton osa suomalaista luontoa ja sen monimuotoisuutta. Ennen ihmisen vaikutusta maamme noin 30 miljoonan hehtaarin maapinta-alasta oli noin kolmasosa, eli 10 miljoonaa hehtaaria suomaa (Turunen 2008, s.319). Soita esiintyy kaikilla mantereilla napa-alueita lukuun ottamatta (Charman 2002, s.17), mutta suurin osa, arviolta noin 87 % niistä esiintyy boreaalisella ja subarktisella kasvillisuusvyöhykkeellä, joihin Suomikin kuuluu (Vitt 2006, s.9). Esimerkiksi Laine et al. (1995, s.785) määrittelevät suon ekologisessa mielessä ekosysteemiksi, jossa korkea vedenpinnan taso saa muodostuvan orgaanisen aineksen kerrostumaan turpeeksi. Geologisen määritelmän mukaan suo on vähintään 30 cm paksu, alle 40 % tuhkaa sisältävä suokasvien maatumisen seurauksena muodostunut turvekerrostuma (Lappalainen et al. 1984). Turetsky et al. (2014, s.11) määrittelevät turpeen orgaaniseksi, vain osittain maatuneista kasvien jäänteistä koostuneeksi maa-ainekseksi, jonka mineraalipitoisuus on alle 20-35 %. Walker (1989, s.37) määrittelee suon biologisesti kosteikko- ja suokasvillisuuden, pääasiassa *Sphagnum* -sammaleiden muodostamaksi turvemuodostumaksi. Rehevillä soilla Suomessa kuitenkin sarakasvit (*Carex spp.*) voivat muodostaa pääasiallisen kasvillisuuspeitteen, ja tällöin turvekin on sarakasvien osista muodostunutta.

#### Soiden synty

Holden et al. (2004, s.95) mukaan maaperän tulee olla vedellä kyllästynyttä eli saturoitunutta, jotta turvetta voi muodostua (Holden et al. 2004, s.95). Soita syntyykin siten alueille, joiden ilmasto suosii soistumista ja kuivatus toimii heikosti, kuten laaksoihin, joista vesi ei pääse poistumaan heikosti vettä läpäisevien maakerrosten takia, tai suistojen mutaikoille (Kemp 1998, s.305). Suomen ilmasto on viileä ja humidinen, eli sadanta on suurempaa kuin haihdunta ja siksi pintavaluntaa esiintyy paljon (Rehell et al. 2018b, s.42; Suomen ympäristökeskus 2020). Maamme tasainen topografia mahdollistaa veden varastoitumisen painanteisiin, mikä edistää maan soistumista (Suomen ympäristökeskus 2020; Rehell et al. 2013b, s.42). Myös järvien umpeenkasvamisen viimeisiä vaiheita on järven soistuminen turvemaaksi, eli niin kutsuttu terrestrialisaatio (Kemp 1998, s.305; Vitt 2006, s.10).



Tavallisin soiden syntymekanismi boreaalisilla alueilla on Vitt'n (2006, s.10) mukaan sekundaarinen soistuminen eli aiemmin kuivemman maan kasvillisuuden peittämän alueen soistuminen vedenpinnan tason nousun ja ilmaston viilentymisen johdosta. Toinen tärkeä, erityisesti edellisen jääkauden jääpeitteiden vetäytyessä vaikuttanut syntymekanismi on primaarinen soistuminen eli paljaan ja tuoreen mineraalimaan soistuminen (Vitt 2006, s.10; Tirri et al. 2001, s.682). Jään vetäytyessä järvivesien täyttämät matalat painanteet ovat myös saattaneet holoseenikauden aikana soistua (Vitt 2006, s.10). Suomessa maanpinnan kohoamisen myötä paljastuneen merenpohjan soistumissukcessio on myös merkittävä paljaan ja tuoreen mineraalimaan soistumismekanismi (Vitt 2006, s.10; Rehell et al. 2012). Edellisen jääkauden aikana Fennoskandiaa ja osaa läntisestä Venäjästä peitti Fennoskandian jääpeite ja soiden muodostuminen oli luultavasti hyvin rajoittunutta, ja siten Suomen boreaaliset ja subarktiset suot ovat syntyneet edellisen jääkauden jäätikkömaksimin jälkeen (Kuhry & Turunen 2006, s.25). Korholan & Tolosen (1996, s.20) mukaan yleisesti ajatellaan, että geologisesti nuorilla alueilla, eli Pohjanlahden rannikkovyöhykkeellä, 40 % suoalasta on syntynyt primaarisesti, 50% sekundaarisesti ja 10% on syntynyt terrestrialisaation kautta. Geologisesti vanhoilla alueilla sisämaassa taas 60 % soista on syntynyt primaarisen soistumisen seurauksena, 35 % sekundaarisesti ja terrestrialisaation seurauksena 5 % suoalasta (Korhola & Tolonen 1996, s.20). Kuitenkin, Korhola & Tolonen toteavat, että terrestrialisaation osuutta soistumismekanismina on aliarvioitu (1996, s.20). Eri mekanismien osuus on myös vaihdellut holoseenikaudella, ja mineraalimaiden soistuminen onkin hidastunut huomattavasti noin 1000 e.a.a., luultavasti potentiaalisten alueiden jo soistuttua (Korhola & Tolonen 1996, s.21).

## **Suotyypit**

Suomalainen suotutkimustraditio on jo melko pitkä: A. K. Cajander (1906) pohti 1900-luvun alussa soiden synty- ja kehitysmekanismeja ja eritteli erilaisia suoluontotyyppejä Suomessa (Lindholm 2013, s.119). Suoluontotyyppien määrittely on vakiintunut pitkälti kansalliseksi, kasvitieteelliseksi perinteeksi mm. Cajanderin myöhemmän, 1913 ilmestyneen ”Studien über die Moore Finnlands” -oppaan myötä ja sittemmin luontotyyppien määrittelyä on tarkennettu vuosisadan kuluessa (Kaakinen et al 2018b, s.119). Eurola et al. (2015) erittelivät teoksessaan ”Sata suotyyppiä – opas Suomen suokasvillisuuden tuntemiseen” 83 erilaista suotyyppiä, kahdeksan lähteikkökasvillisuustyyppiä sekä kuusi suoarotyyppiä, ja lisäksi Eurola ja Virtanen (1991) erittelevät Pohjois-Lapin tunturisuotyyppijä (Kaakinen et al. 2018b, s.119).

Viimeisimmässä Suomen luontotyyppien uhanalaisuusarvioinnissa (Kaakinen et al. 2018b, s.119) eritellään suoluontotyytit päätyyppiryhmiin, joita ovat korvet, rämeet, nevat, letot sekä näiden yhdistelmätyypeinä neva- ja lettokorvet ja neva- ja lettorämeet, ja nämä pääryhmät jaetaan vielä alaryhmiin tai luontotyyppihin päätyyppiryhmien alla.

Suoluontotyyppien jaottelu Suomessa pohjautuu suoekologisiin vaihtelusuuntiin, joista tärkeimpiä ovat reuna- tai keskustavaikutteisuus, suoveden alkuperä, ravinteisuus ja happamuus sekä suovedenpinnan taso (Kaakinen et al. 2018b, s.120; Holden et al. 2004, s.96). Vaihtelusuuntia ilmentävät kasvilajit, joiden avulla suoluontotyytit voidaan tunnistaa. Bragazza & Gerdolin (1999, s.243) mukaan suot voidaan jakaa neljään tyyppiin suoveden alkuperän mukaan: ombrogeenisiin, topogeenisiin, soligeenisiin ja limnogeenisiin soihin. Ombrogeeniset suot saavat vetensä pelkästään sateena. topogeeniset suot saavat osan vedestään seisovasta tai vain vähän virtaavasta pohjavedestä, soligeeniset suot ovat lähdevaikutteisia ja vedenpinnantaso on kalteva, kun taas limnogeeniset suot ovat tulvavesille altisteisia (Bragazza & Gerdol 1999, s.243). Suomalaisessa suotutkimuksessa käytetään yleisesti termejä ombro- ja minerotrofia (esim. Rehell et al. 2013b, s.48), jotka kuvastavat kasvupaikan ravinteiden saatavuutta, johon kuitenkin vaikuttaa ratkaisevasti suoveden alkuperä: ombrotrofinen suo saa vetensä sateena ja sulamisvesinä, kun minerotrofinen suo on myös ympäröiviltä mailta tulevan tai pohjaveden vaikutuksen alaisena (Salonen & Heinonen 2010a). Ombrotrofinen suo on siis ombrogeeninen ja minerotrofinen suo voi olla topogeeninen, soligeeninen tai limnogeeninen riippuen suoveden alkuperästä. Lisäksi minerotrofia jaetaan tasoihin ravinteisuuden ja kasvillisuuden rikkauden mukaan, joita ovat eutrofia, mesotrofia ja oligotrofia. Näistä eutrofinen suo on rehevin ja oligotrofinen karuin minerotrofinen suo. Suoluontotyyppien uhanalaisuusarvioinnissa (Kaakinen et al. 2018b) käytetään oligo-, meso- ja eutrofiasta termejä karu, ruohoinen ja lettoinen.

Ombrotrofisella suolla kasvit tulevat siis toimeen vain sade- ja sulamisveden mukanaan tuomien ja turpeessa jo olevien ravinteiden voimin. Useimmiten tällaiset suot ovat karuja ja happamia, sisältävät vähän kalsiumia ja magnesiumia, ja suotyyppiä ilmentää nevaisuus, lettoisuus ja rämeisyys (Holden et al. 2004, s.96, Kaakinen et al. 2018, s.120). Nevat ovat avoimia, märkiä ja vähäravinteisia soita, joilla vedenpinnan tason vaihtelu WTF on melko voimakasta, kun taas letot taas ovat runsasravinteisempia avosoita (Salonen & Heinonen 2010c, 2010d). Nevat ovat usein väli- tai rimpipintaisia ja paksuturpeisia (Kaakinen et al. 2018b, s.381). Niillä varpujen esiintyminen on vähäistä,

ja kasvillisuutta kenttäkerroksessa edustavatkin pääasiassa sarat (*Carex spp.*) ja ruohot (Kaakinen et al. 2018b, s.381). Nevarämeet ovat mosaiikkimaisia suoluontotyypppejä, joiden rimpi- ja välipinnoilla vallitsee nevakasvillisuus ja mätäspinoilla rämekasvillisuus (Kaakinen et al. 2018b, s.367). Rämeet ovat maamme yleisimpiä suoluontotyypppejä (Salonen & Heinonen 2010e). Ne ovat melko kuivia, pääosin karuja, mätäspintaisia ja paksuturpeisia, mäntyä (*Pinus sylvestris*) kasvavia soita (Kaakinen et al. 2018b, s.352; Salonen & Heinonen 2010e). Rämekasvillisuuteen kuuluvat korkeat varvut, kuten suopursu (*Rhododendron tomentosum*) ja vaivaiskoivu (*Betula nana*) (Kaakinen et al. 2018b, s.352).


Reunavaikutteiset ja minerogeeniset suot saavat vetensä sateen ja sulamisveden lisäksi ympäröiviltä mineraalimailta tai pohjavetenä, jolloin veden mukana huuhtoutuu ravinteita suolle, joita se pidättää kemiallisten ja biologisten prosessien kautta (Rehell et al. 2013b, s.48; Kaakinen et al. 2018b, s.120; Holden et al. 2004, s.96). Minerogeenisillä soilla virtaus on usein myös voimakkaampaa kuin ombrogeenisillä (Rehell 2013b, s.57). Turpeesta liukenee virtaavaan veteen erityisesti hajoamisprosesseissa syntyviä orgaanisia happoja, jotka poistuvat suolta valumaveden mukana, suon vesi pysyy emäksisempänä, ja kasvillisuuskin on rikkaampaa kuin keskustavaikutteisilla tai ombrogeenisillä soilla (Kaakinen et al. 2018b, s.120; Holden et al. 2004, s.96; Rehell et al. 2013b, s.48). Reunavaikutteisuuden ilmeneminen näkyy luhtaisuutena, lähteisyytenä ja korpisuutena (Kaakinen et al. 2018b, s.120). Luhtaisuudella tarkoitetaan liikkuvien pintavesien aiheuttamaa vaikutusta kasvillisuuteen, kun taas lähteisyys on liikkuvien pohjavesien aiheuttamaa vaikutusta (Salonen & Heinonen 2010a). Lähde onkin pohjaveden pintaesiintymä. Korvet ovat usein ohutturpeisia, puustoisia soita, joissa puulajeina vallitsevat usein kuusi, hieskoivu ja lepät, mutta muitakin lehtipuita ja mäntyä voi esiintyä (Salonen & Heinonen 2010b).

Kaakisen et al. (2018b, s.120) mukaan suoveden taso, tai pikemmin etäisyys suon pinnasta vedenpinnan tasoon, vaikuttaa kasvualustan happamuuteen, happipitoisuuteen ja ravinteiden saatavuuteen. Soiden eri osissa erilainen vedenpinnan taso suosii erilaisten kasvilajien menestymistä (Kaakinen et al. 2018b, s.120). Suomalaisille soille on usein tyypillistä jänteiden ja rimpien tai kuljujen ja kermien, sekä välipintojen vaihtelu, ja näille eri mikrotopografisille muodostumille ovat tyypillisiä erilaiset kasvilajit ja vedenpinnan taso (Kaakinen et al. 2018b, s.120). Aapasoiden rimmet ja keidassoiden kuljut ovat soiden märempiä pintoja, joita rajaavat kuivemmat jänteet ja kermi (Aapala et al. 2013a, s. 76;

Salonen & Heinonen, 2010a). Letto-, neva- ja luhtakasvillisuus on ominaista väli- ja rimpipinnoille, kun taas räme- ja korpikasvillisuus kasvaa pääasiassa mätäspinoilla (Kaakinen et al. 2018b, s.120). Ruoppapinnoilla tai ruopparimmillä tarkoitetaan märimmillä soilla tavattavia märkäpintoja, joissa kasvillisuus on harvaa ja paljasta turvetta on näkyvissä paljon (Aapala et al. 2013a, s.76). Ruoppapinnoilla turpeen muodostuminen saattaa olla jopa vähäisempää kuin sen hajoaminen, ja hajoamisen johdosta tuloksena saattaa syntyä syviä allikoita (Aapala et al. 2013a, s.76). Aapala et al. (2013a, s.76) mukaan syynä voi olla esimerkiksi leväkasvuston tuottama happi tai muualta tuleva hapekas vesi, joka kiihdyttää aerobista hajoamista. Välipinnoilla tarkoitetaan mättään ja märkäpinnan välimuotoa, jossa vedenpinnan taso saattaa kasvukaudella olla suon pinnan yläpuolella, mutta useimmin on kuitenkin sen alapuolella melko lähellä pintaa (Aapala et al. 2013a, s.76). Välipintoja esiintyy eniten nevoilla ja letoilla, joissa mätäspintojen peittävyys voi jäädä vähäisemmäksi (Aapala et al. 2013a, s.76). Rehell et al. (2013b, s.46) mukaan kaikenlaisilla suosysteemeillä kuivapinnat vaihtelevat märempien pintojen kanssa niin, että ne muodostavat pitkiä ja kapeita, viettäviä ”kynnyksiä” ja tasaisempia ja märempiä altaita kohtisuorassa veden virtaussuuntaa vastaan (Rehell et al. 2013b, s.46). Heikkilä & Lindholm (1995, s.549) toteavat artikkelissaan, että vain suuret suot muodostavat todellisia suokomplekseja, eikä pienemmillä soilla tavallisesti ole selvästi havaittavia suurten kompleksien rakenteita, kuten jänne-rimpi- tai kermi-kulju-vaihteluita. Pienemmät suot kuitenkin muodostavat usein edustavia verkostoja mineraalimaaharjujen kanssa, jotka ovat tärkeitä suojelun ja ennallistamisen kohteita (Heikkilä & Lindholm 1995, s.549-550).

### **Suoyhdistymät**

Suot harvoin edustavat tiettyä, yksittäistä suoluontotyyppiä, vaan ovat pikemmin eri suoluontotyyppien yhdistelmiä eli suoyhdistymiä. Kaakinen et al. (2018b, s.120) määrittelevät suoyhdistymän useista suotyypeistä koostuvaksi ekohydrologisesti yhtenäiseksi suoalueeksi tai suosysteemin osaksi. Suoyhdistymätyypit vaihtelevat maantieteellisesti pohjoiseteläsuunnassa ilmastollisten lämpö- ja kosteusolosuhteiden vuoksi, mutta paikallisen ympäristön ominaisuudet, kuten topografia, hydrologia, mineraalimaan, kallion ja lähistön vesistöjen sijainnit ja koostumukset vaikuttavat paikallisten yhdistymätyyppien syntyyn (Kaakinen et al. 2018b, s.120). Ilmastollisia yhdistelmätyyppejä Suomessa ovat aapa-, keidas- ja rinnesuot sekä pohjoiset palsasuot ja eteläiset sarasuot (Kaakinen et al. 2018b, s.120) (*Kuva 1*).



Kuva 1. Yleisimmät pitkälle kehittyneet suoyhdistymätyypit Suomessa (geologia.fi). *Sphagnum* viittaa rahkasammalturpeeseen, *Carex* saraturpeeseen ja *Bryales* hiirensammalturpeeseen.

Kaakisen et al. (2018b, s.120) mukaan ilmasto vaikuttaa pääasiassa mätäs-, väli- ja rimpipintojen suhteisiin; eteläisessä Suomessa pitkälle kehittyneet suot ovat pääasiassa mätäspintaisia, ombrotrofisia, keskivaikutteisia keidassoita, kun taas pohjoisessa ne ovat pääasiassa minerotrofisia rimpipintaisia aapasoita (Kuva 1), ja keskisessä Suomessa minerotrofisia välipintaisia soita. Keidassoilla turvepinta on niin paksu, että keskiosa suosta on kasvanut sen laitoja korkeammalle (Kuva 1) ja suo saa vetensä ja ravinteensa

pääasiassa sateena ja osin laskeumana, lukuun ottamatta laita-alueiden minerotrofisia osia (Kaakinen et al. 2018b, s.120, 132). Suomen luontotyyppien uhanalaisuusarvioinnissa (Kaakinen et al. 2018b, s.123) keidassuot on jaettu kermikeitaisiin ja rämekeitaisiin, ja edelleen vielä alayhdistymätyyppeihin topografian, rimpipintojen esiintyvyyden ja kasvillisuuden mukaan. Aapasoilla suon keskialue ei nouse sen reunoja korkeammalle (*Kuva 1*) ja ne säilyvät siis minerotrofisina saaden vettä ympäröiviltä mailta valuntana (Kaakinen et al. 2018b, s.123, 133; Rehell et al. 2012, s.39). Tarkasteltaessa veden virtausta aapasoilla, ne jaetaan luovuttaja- ja vastaanottajaosiin. Luovuttajaosat ovat topografisesti ylempänä ja pääasiassa rahkasammaleisia, ja niissä virtaus on pääasiallisesti vähäistä, kun taas vastaanottajaosat ovat alempana ja rimpisiä, ja niihin virtaa vettä suurelta alueelta ja virtaus on voimakkaampaa (Rehell et al. 2013b, s.46). Luovuttaja- ja vastaanottajaosat voidaan erottaa toisistaan virtausviiva-analyysillä ja usein ne voidaan erottaa melko hyvin jo alueen ilmakuvista, sillä vastaanottajaosalle tyypillisiä ovat jänteiden ja rimpien (avovesipintojen) vaihtelu portaittaisesti, kun luovuttajaosassa rahkasammaleen peittävyys voi olla lähes täydellistä (Rehell et al. 2013b, s.46). Rimpipintojen säilyvyyden kannalta on olennaista riittävä virtaus (Rehell et al. 2013b, s.46). Aapasuot jaoteltiin luontotyyppien uhanalaisuusarvioinnissa (Kaakinen et al. 2018b, s.123) pohjoisboreaalisiin ja keskiboreaalisiin aapasoihin, joista keskiboreaaliset sijaitsevat Pohjanmaalla ja pohjoisboreaaliset Metsä-Lapissa ja Peräpohjolassa. Lisäksi uhanalaisuusarvioinnissa (Kaakinen et al. 2018b, s.123) yhdistymätyypeinä on arvioitu erikseen rinne- ja palsasuot, joilla on oma maantieteellinen esiintymisalueensa, paikalliset suoyhdistymät, jollaisia ovat mm. boreaaliset piensuot, rannikkosuot ja tunturisuot, sekä maankohoamisrannikon soiden kehityssarjat. Maankohoamisrannikon soiden kehityssarjat ovat Suomelle lähes endeemisiä (Kaakinen et al. 2018b, s.123).

Suomen luontotyyppien uhanalaisuusarvioinnin suoluonnon asiantuntijaryhmän mukaan suoluontoa tulisi tarkastella myös ”suosysteemitasolla ja suomalaisetasolla”. Koska suon hydrologiaan ja siten sen toimintaan ja sukkessioon suolla vaikuttaa koko valuma-alueen maankäyttö, tulisi suoluonnon säilyttämisessä tarkastella myös näitä laajempia kokonaisuuksia. Suolle tulevan veden määrän ja laadun muutos voi vaikuttaa ratkaisevasti sen eri osien sukkessioon ja siten muuttaa suoluontotyyppien luontaista toimintaa ja lopulta niiden esiintyvyyttä. (Kaakinen et al. 2018b, s.123)

## 2.2 Suot hiilen ja veden varastona

Suot sisältävät noin 30 % maapallon maaperään varastoituneesta hiilestä (C), vaikka ne peittävät vain noin 3 % sen pinta-alasta (Wieder & Vitt 2006). Soiden vertikaalinen vuotuinen kasvuvauhti on 0,2-4,0 mm, keskiarvon ollessa 0,5 mm (Korhola & Tolonen 1996, s.24). Korholan & Tolosen (1996, s.25) mukaan riippuen muun muassa suotyyppistä, maantieteellisestä sijainnista ja iästä, suot voivat kerryttää hiiltä 8,1-23,0 g neliömetrille vuodessa; tilastotieteellinen keskiarvo on 12,1 g/m<sup>2</sup>/a. Lisäksi turpeeseen kertyy ilmakehästä typpeä (N<sub>2</sub>) (Laine et al. 2006, s.331). Vanhemmat suot kerryttävät vähemmän turvetta kuin nuoremmat (Kuhry & Turunen 2006, s.39). Erityisesti pitkälle kehittyneillä suoluontoyhdistelmillä (*Kuva 1*), kuten keidassoilla rahkasammalet (*Sphagnum spp.*) muodostavat pääasiallisen pohjakerroksen peitteen, ja sellaisilla soilla ne tuottavatkin pääosan turpeesta. Erilaisilla suotyypeillä kuitenkin suokasvillisuus on erilaista, ja esimerkiksi rehevämmillä soilla sarakasvit saattavat muodostaa pääosan kenttä- ja pohjakerroksen biomassasta, ja siten tuottavat pääosan turpeesta. Eri kasveista muodostuu erilaista turvetta, jolla on erilaisia fysikaalisia ominaisuuksia, jotka heijastuvat myös suon hydrologisiin ominaisuuksiin, kuten vedenjohtavuuteen K (esim. Rehell et al. 2013b, s.45).

Kuhry & Turusen (2006, s.37) mukaan noin 5-10 % soilla syntyvästä biomassasta muuttuu turpeeksi ajan myötä, josta osa hajoaa myöhemmin turpeen syvemmissä kerroksissa anaerobisen hajoamisen myötä. Osa hiilestä voi hajoamisen myötä vapautua metaanina (CH<sub>4</sub>) ilmakehään, ja osa voi poistua liuenneena hiilenä virtaavan veden mukana (Laine et al. 2006, s.341). Osa turpeeseen kertyvästä tyydestä muodostaa nitrifikaation ja denitrifikaation myötä dityppioksidia (N<sub>2</sub>O), joka on kuitenkin luonnontilaisilla soilla vähäistä turpeen anaerobisuuden takia (Laine et al. 2006, s.341). Suon CO<sub>2</sub>-ekvivalenttibalanssi riippuu mm. ravinteisuudesta ja WTD:stä (Ojanen 2020). Pääasiallisesti rehevien soiden hiilidioksidiekvivalentti on positiivinen, eli ne päästävät kasvihuonekaasuja ilmakehään enemmän, kuin sitovat niitä itseensä (Ojanen 2020). Karuilla soilla CO<sub>2</sub>-ekvivalenttibalanssi on sopivalla WTD:llä negatiivinen: vaihteluväli negatiiviselle CO<sub>2</sub>-ekvivalenttibalanssille on noin WTD = -10...-35cm, eli WT sijaitsee 10:stä 35 cm:iin suon pinnan alapuolella (Ojanen 2020). Kun WT laskee syvemmälle turpeessa, hiilidioksidin merkitys kaasupäästönä kasvaa turpeen altistuessa aerobiselle hajotukselle, ja kun WT nousee lähemmäs suon pintaa, metaanipäästöt kasvavat ja ottavat merkittävän roolin CO<sub>2</sub>-ekvivalentissa (Ojanen 2020).

Turvekerroksen rakennetta suolla voidaan kuvata nk. diplotelmisellä mallilla, jossa turpeen ajatellaan jakautuvan ylempään, huokoisempaan ja vähemmän maatuneeseen kerrokseen eli akrotelmaan, sekä alempaan, tiheämpään ja tiiviimpään, maatumisessa pitemmälle ehtineeseen katotelmaan (Rehell et al. 2013b, s.41, 44; Kuhry & Turunen 2006 s.37). Akrotelma on niin huokoinen, että se märillä soilla liikkuu vedenpinnan vaihtelun mukaan (Rehell et al. 2013b, s.41). Diplotelminen malli olettaa, että katotelman vedenjohtavuus  $K$  on niin pieni, että virtauksen voidaan katsoa olevan lähes olematon. Vedenjohtavuus eli hydraulinen johtavuus  $K$  [m/s] on maa-aineksen ominaisuus, joka kuvaa sen vedenläpäisykykyä. Suoveden liike keskittyy siis mallissa huokoiseen akrotelmaan ja pintavalunnaksi (Rehell et al. 2013b, s.44). Akrotelman ja katotelman rajapinnaksi ajatellaan pintaa, johon vesi keskimääräisesti asettuu kesän kuivimpana kautena (Kuhry & Turunen 2006, s.37). Diplotelminen malli on kehitetty kuvaamaan pääasiassa keidassoiden hydrologiaa, mutta se voidaan yleistää myös muihin suotyyppeihin (Rehell et al. 2013b, s.41). Kuitenkin, esimerkiksi pohjavesivaikutteisilla soilla veden liikettä tapahtuu myös pystysuunnassa mineraalimaasta turpeeseen, tai päinvastoin, pohjavettä voi muodostua suovedestä, jolloin vesi suotautuu turpeesta alapuoliseen mineraalimaahan. Tällaisissa tapauksissa diplotelminen malli ei päde (Rehell et al. 2013b, s.45). Diplotelmisesta mallista poikkeavat myös Suomessa yleiset suot, joissa akrotelma on hyvin paksu ja saraturpeesta muodostunut katotelma johtaa myös vettä hyvin. Tällaisten soiden ajatellaan noudattavan perkolaatio- eli läpivirtaussuomallia, jossa koko turvekerros johtaa vettä yhtä hyvin (Rehell et al. 2013b s.45). Yleisesti ajatellaan kuitenkin virtaavan suolla sen pinnan kaltevuuden mukaisesti pääasiassa akrotelmassa. Kuivuuden aikana virtaus laskee lähelle nollaa ja voimakkaan virtauksen aikaan esimerkiksi kevään sulamisvesien aikaan pintavalunta on vallitsevaa (Rehell et al. 2013b, s.44).

Suolla vedenpinnan taso ja virtauksen määrä vaikuttavat ratkaisevasti esiintyviin kasvilajeihin. Pohjavedenpinnan tasoksi WT (*Kuva 9*) katsotaan taso, jossa veden paine on yhtä suuri vallitsevan ilmanpaineen kanssa, eli se taso, johon pohjavesi asettuu vettä läpäisevässä kaivossa, jossa kapillaarisen nousun voidaan katsoa olevan nolla (esim. Rehell et al. 2013b, s.41, Rehell 2013a, s.56). Pohjavedenpinnan tason yläpuolella maa-aineksessa olevaa vettä kutsutaan maavedeksi (Ronkanen 2019a). Kuitenkin, soiden vedet poikkeavat mineraalimaiden pohjavesistä niin paljon, että niistä käytetään yleisesti nimitystä suovesi (esim. Rehell et al. 2013b, s.41). Soilla pintavesi on vettä, joka muodostaa pysyviä tai ajoittaisia avovesipintoja, siis rimpiä tai kuljuja, noroja tai



suonsilmäkkeitä eli allikoita (Rehell et al. 2013b, s.41). Aapala et al. (2013, s.76) mukaan mätäspinnoilla suovesi on vähintään 20 cm syvyydessä kasvukaudella, eivätkä ne jää veden peittämiksi tavallisesti koko kasvukauden aikana. Välipinnoilla taas suovesi on kasvukaudella 5-20 cm syvyydessä ja voi olla ajoittain maanpinnan yläpuolella. Rimpi- ja kuljupinnoilla, eli soiden märkäpinnoilla suovesi on koko kasvukauden lähellä suon pintaa tai sen yläpuolella. Soiden eri pintojen erilaiset kasvilajit ovat vuorovaikutuksessa keskenään: esimerkiksi rahkasammalten ajatellaan olevan soiden avainlajeja, sillä ne pystyvät säätelemään kasvuston kosteutta niin, että kuivempinakin ajanjaksoina suon pinta pysyy kosteana ja vettä riittää muillekin lajeille kasvuun. (Aapala et al. 2013a, s.76)

Turpeen huokoskoko pienenee tiheyden kasvaessa, mikä mahdollistaa suuremman kapillaarisen nousun (Päivänen 1973, s.56-57). Turpeessa kapillaarinen nousu on yleisesti yli metrin, joskin se vaikeutuu merkittävästi, kun ylitetään turpeen tiheydestä riippuen 40-70 cm raja pohjavedenpinnasta, jolloin matrikpotentiaali  $\psi$  turpeen pintakerroksessa kasvaa eksponentiaalisesti (Päivänen 1973, s.56-57). Matrikpotentiaali  $\psi$  [cm] on maa-aineksessa vallitseva, huokoskoosta (ja siten maa-aineksen partikkelien koosta ja muodosta) riippuva paine, joka kuvaa myös kasveille käytettävissä olevan vapaan veden määrää maassa (Rossi 2019b). Tavallisessa tapauksessa pohjavedenpinnan yläpuolella  $\psi$  on negatiivinen verrattuna ilmanpaineeseen ja maa-aines pyrkii ”imemään” vettä kapillaarisesti pohjavedestä (Rossi 2019b). Pohjavedenpinnan alapuolella  $\psi$  on taas positiivinen verrattuna vallitsevaan ilmanpaineeseen (Rossi 2019b). Turvemailla tärkeä ilmiö on hystereesi, joka tarkoittaa, että kuivan turpeen vesipitoisuus on eri riippuen siitä, onko turve kastumassa vai kuivumassa, eli turpeen vesipitoisuus voi olla eri, vaikka imu olisi sama (Ronkanen 2019b).

Suon hydrologia ja turpeen ominaisuudet heijastuvat myös suoveden laatuun. Kaakisen et al. (2018b, s.120) mukaan puhuttaessa soista ravinteisuudella ei viitata niinkään pelkästään suoveden ravinnepitoisuuteen, vaan ennemminkin sen happamuuteen tai kalkkipitoisuuteen. Veden happamuus vaikuttaa kasvilajien ominaiseen ionienvaihtokykyyn, ja suovesi saattaakin olla ravinteikasta, mutta hapanta, jolloin vaateliaat lajit eivät pysty hyödyntämään vedessä olevia ravinteita (Kaakinen et al. 2018b, s.120). Ombrotrofisilla soilla suoveden kalsiumpitoisuus on alle 0,5 mg/l ja pH alle 4,2 (Rehell et al. 2013b, s.48). Minerotrofisilla soilla suoveden kemialliset tunnuksat menevät osin päällekkäin eri ravinteisuuden tasoilla: eutrofisen suon pH voi vaihdella välillä 5,5-8,5 ja kalsiumpitoisuus olla vain 2 mg/l tai yli 20 mg/l, oligotrofisen suon pH on n. 5 ja

mesotrofisen vaihtelee välillä 4,5-6 (Rehell et al. 2018b, s.48). Rehell et al. (2013b, s.48) mukaan sammallajisto heijastaa suoveden laatua tarkasti, ja tunnistamalla suolla esiintyviä lajeja voidaan tehdä päätelmiä suoveden ravinteisuudesta ja happamuudesta, ja siten myös yleisluontoisia päätelmiä virtauksesta ja veden alkuperästä. Kuitenkaan oligotrofisilla soilla kasvillisuus ei välttämättä osoita suon olevan minerotrofinen, mutta suoveden laatu viittaa esimerkiksi raudan ja alumiinin pitoisuuksien osalta minerotrofiaan (Tahvanainen et al. 2012, Rehell et al. 2018b, s.48 mukaan).

### 2.3 Suoluonnon uhanalaisuus

Suomen luontotyyppien uhanalaisuusarviointi (Kaakinen et al. 2018a, s.317) eli Luontotyyppien punainen kirja erittelee Suomessa esiintyvän 69 erilaista suoluontotyyppiä tai luontotyyppiyhdistelmää, joista se luokittelee 39 uhanalaisiksi (luokat CR = äärimmäisen uhanalainen, EN = erittäin uhanalainen ja VU = vaarantunut). Etelä- ja Pohjois-Suomessa katsotaan molemmissa esiintyvän 46 ja koko maassa 50 erilaista suoluontotyyppiä (Kaakinen et al. 2018b, s.134). Koko maassa katsottiin olevan 19 erilaista soiden luontotyyppiyhdistelmää, joista Etelä-Suomessa esiintyy 13 ja Pohjois-Suomessa yhdeksän (Kaakinen et al. 2018b, s.134). Koko maan tasolla näistä 12 arvioitiin uhanalaisiksi: Etelä-Suomessa kaikki 13 luontotyyppiyhdistelmää katsottiin uhanalaisiksi, kun taas Pohjois-Suomen yhdeksästä ainoastaan palsasoiden katsottiin olevan uhanalaisia (Kaakinen et al. 2018b, s.134). Pohjois-Suomeksi uhanalaisuusarvioinnissa (Kaakinen et al. 2018a, s.36) katsotaan pohjoisboreaalinen metsävyöhyke. Etelä-Suomi taas on hemi-, etelä- ja keskiboreaalista metsävyöhykettä (Kaakinen et al. 2018a, s.36). Raja Etelä- ja Pohjois-Suomen välillä ulottuu karkeasti Pellosta Rovaniemen, Ranuan ja Iso-Syötteen kautta Suomussalmen pohjoispuolelle. Kokonaisuudessaan suoluontotyypistä tai luontotyyppiyhdistelmistä n. 56 % katsottiin olevan uhanalaisia.

Luontotyypeistä uhanalaisia ovat lähes kaikki korvet, neva- ja lettokorvet ja letot, sekä useat rämeet, neva- ja lettorämeet, luhdat, Etelä-Suomen sarasuot sekä luontotyyppiyhdistelmistä keskiboreaaliset aapasuot, keidassuot sekä rannikkosuot. Myös Suomelle lähes endeemiset maankohoamisrannikon aapa- ja keidassoiden kehityssarjat ovat uhanalaistuneita. Kauttaaltaan suot ovat uhanalaistuneempia Etelä-Suomessa, kuin Pohjois-Suomessa. Kuitenkaan joitakin suotyyppejä, kuten tunturien

soita, ikiroutasoiita ja palsasoiita ei löydy Etelä-Suomesta, ja niiden esiintyminen Suomessa on Pohjois-Suomen esiintymien varassa. (Kaakinen et al. 2018a, Liite 3.)

Valtakunnallisesti uhanalaisimpia, eli äärimmäisen uhanalaisia (CR) ovat välipintakoivuletot ja kalkkiletot (Suomen ympäristökeskus 2020). Molemmat ovat lähteisyyttä ja luhtaisuutta ilmentävien lajien koteja ja useimmat kalkkilettojen tunnusomaiset lajit ovat harvinaisia (Kaakinen et al. 2018b, s.404, 411). Toiseksi uhanalaisimmaksi, eli erittäin uhanalaiseksi (EN) on luokiteltu varpu-, metsäkorte-, juolasara- ja muurainkorvet, kangaskorvet, korpirämeet, palsarämeet, rimpiset koivuletot, välipintaletot sekä tervaleppä- ja harmaaleppäluhdet (Suomen ympäristökeskus 2020). Soiden uhanalaisuuden kehityssuunta on suurimmaksi osaksi heikkenevä, erityisesti Etelä-Suomessa, jossa yli 80 % suoluontotyypeistä tai luontotyyppiyhdistelmistä katsotaan kehittyvän heikompaan suuntaan – Pohjois-Suomessa vastaava luku on noin 30 % (Kaakinen et al. 2018a, s.321).

Yleisesti merkittävimmiksi luontotyyppien uhanalaistumisen syiksi katsottiin metsien uudistus- ja hoitotoimet, ojitus, pellonraivaus, rakentaminen ja vesien rehevöityminen (Kaakinen et al. 2018, s.321). Näistä neljä ensimmäistä siis ovat suoraan soitaa uhanalaistavia tekijöitä. Metsien uudistus- ja hoitotoimenpiteitä katsotaan olevan esimerkiksi maanmuokkaus, kantojen nosto ja metsittäminen, sekä muut hoitotoimet, jotka eivät sisälly luontaisen sukkession, kuloalueiden, lahoppaan tai vanhojen metsien vähenemiseen tai metsien puulajisuhteiden muutokseen (Kaakinen et al. 2018a, s.35). Metsien uudistus- ja hoitotoimenpiteet ovat yksi tärkeimmistä syistä suoluontotyyppien uhanalaistumiseen, ja ne vaikuttavat suopuuston lisäksi soiden vesitalouteen soilla tai niiden ulkopuolella tapahtuvien toimenpiteiden kautta (Kaakinen et al. 2018a, s.321). Ojitus on suurin soitaa uhanalaistava tekijä, ja sillä on vaikutuksensa myös pienvesiin ja muihin kosteisiin kasvupaikkoihin: ojitus heikentää ojitusalueiden alapuolisten vesistöjen laatua ja valuma-alueen vedenpidätyskykyä (Kaakinen et al. 2018a, s.321; Lammi et al. 2018, s.109). Ojituksen ja metsätalouden katsotaan olevan merkittävimpiä syitä myös lähteikköjen heikentyneeseen tilaan ja katoamiseen (Lammi et al. 2018, s.109). Pellonraivaus on uhanalaistanut erityisesti reheviä suoluontotyyppejä, kuten lettoja ja reheviä korpia jo pitkään – kuitenkin pellonraivauksen ei katsota aiheuttavan tulevaisuudessa suurta uhkaa luontotyypeille (Kaakinen et al. 2018a, s.321).

Rakentaminen on neljäs suurimmista suoluontotyyppien uhanalaistumisen syistä (Kaakinen et al. 2018a, s.321). Esimerkiksi tierakentaminen usein pirstoo suoalueita ja ennallistamistilanteissa tien rikkoman suoyhdistymän hydrologisen eheyden palauttaminen voi olla vaikeaa. Laidunten perinteisen käytön päättymisestä ja rehevöittävistä ravinnelaskeumista johtuva umpeenkasvu on uhanalaistumisen syy erityisesti letoilla, joita rehevinä, saraicina suoalueina on aiemmin käytetty karjan vapaina laidunnusalueina (Kaakinen et al. 2018a, s.323).

Tulevaisuuden uhat ovat pitkälti samankaltaisia kuin tähän mennessä uhanalaistumista aiheuttaneet syyt, sillä erotuksella, että pellonraivauksen ei katsota tulevaisuudessa aiheuttavan yhtä suurta uhkaa kuin aiemmin ja tulevaisuudessa ilmastonmuutoksen ja vieraslajien merkitys on suurempi (Kaakinen et al. 2018a, s.323). Kunnostusojituksia tehdään yhä, mutta uudisojitusten määrä on laskenut käytännössä nolnaan (Palviainen & Finér 2013, s.5). Lisäksi rahkasammalen keruu kaupallisiin tarkoituksiin saattaa aiheuttaa tulevaisuudessa eriasteista uhkaa tietyille suoyhdistymätyypeille riippuen keruun laajuudesta (Kaakinen et al. 2018b, s. 150). Ilmastonmuutos vaarantaa esimerkiksi arktiset palsasoiden tulevaisuuden, kun niillä esiintyvät ikeiroutamuodostelmat eli palsat ja pounikot sulavat ilmaston lämpenemisen myötä: palsasuot ovat jo nyt kriittisen uhanalaisia (CR) Euroopassa (Kaakinen, Kokko & Aapala 2012; Eskola 2018). Ruuhijärven (2018) mukaan tutkijat ovat melko yksimielisiä palsasoiden häviämisestä vuosisadan loppuun mennessä ilmastonmuutoksen myötä. Kaakisen et al. (2019a, s.326) mukaan ilmaston suuren lämpenemisnopeuden myötä voidaan odottaa, että luontotyypit muuttuvat eri lajien reagoidessa lämpenemiseen eri tavoin. Esimerkiksi Dieleman et al. (2014) huomasivat rahkasammaleiden vähentyvän, kun keskilämpötila ylitti 8 °C ja sarakasvien yleistyvän sen ylittäessä 4 °C. Ontariossa, Kanadassa tehdyssä tutkimuksessa altistettiin boreaalisen ombrotrofisen leton palstoja kohonneille lämpötiloille, hiilidioksidipitoisuuksille ja erilaisille vedenpinnantasojille. Ruuhijärven (2018) mukaan eteläborealisilla soilla mätäspinnat entisestään laajenevat ja kuivuvat ilmastonmuutoksen myötä ja keidassuovyöhyke siirtyisi mahdollisesti pohjoisemmaksi.

Vuonna 2018 valmistunutta Suomen luontotyyppien uhanalaisuusarviointia (Kaakinen et al. 2018a) ei voida suoraan verrata ensimmäiseen, vuonna 2008 valmistuneeseen uhanalaisuusarviointiin, sillä aiempi tehtiin kansallisen arviointimenetelmän mukaan, kun uudessa arvioinnissa on käytetty kansainvälistä IUCN-menetelmää (Kaakinen et al.

2018a, s.323). Silti kymmenessä vuodessa esimerkiksi kangas- ja varpukorpien katsottiin uhanalaistuneen ainakin osittain aidon muutoksen takia (Kaakinen et al. 2018a, s.323).

Laaja luonnonsuojelualueiden ja Natura 2000 -alueiden verkosto auttaa osaltaan säilyttämään tärkeimpiä suoalueitamme (Kaakinen, Kokko & Aapala 2012). Kuitenkaan erityisesti Etelä-Suomessa suojelualueiden rajat eivät välttämättä sisällä soita hydrologisina kokonaisuuksina, ja suojelualueen ulkopuoliset toimet saattavat heikentää suojellunkin suoalueen tilaa ja estää luonnollisen vesitalouden toteutumisen (Kaakinen, Kokko & Aapala 2012). Lisäksi, jos koko suoalue ei kuulu suojelualueeseen, voi suojelualueen ulkopuolinen, ojitettu osa rajoittaa ennallistamisen kannattavuutta (Rehell et al. 2013a, s.33). Suomen luontotyyppien uhanalaisuusarvioinnissa (Kaakinen et al. 2018) katsottiin, että suoluontotyypeistä yhdenkään kehitystilanne ei ole parantuva, noin viidesosan tilanne on vakaa, ja loppujen kehityssuunta on heikkenevä koko maan mittakaavassa (Suomen ympäristökeskus 2020).

## **2.4 Soiden ojituksen seuraukset**

Soita on ojitettu ympäri maailman esimerkiksi maa- ja metsätalouden tarpeisiin ja turpeen energiakäyttöä varten, ja niin myös Suomessa. Suomi on maailman intensiivisimmin suo- ojitettu maa (Riipinen 1993; Baldock 1984, Holden et al. 2006, s.1764 mukaan). Toisen maailmansodan jälkeen suuret sotakorvaukset ja metsätalouden halvan raaka-aineen tarve johtivat laajamittaiseen ojitukseen, joka oli intensiivisimmillään 1960- ja 1970-luvuilla, jolloin soita ojitettiin 200 000-300 000 ha vuosivauhtia (Rönty 2020). Metsätalouden ojitukset ovat vaikuttaneet yli puoleen koko Suomen pinta-alasta (Aapala et al. 2012, s.197), ja Aarne et al. (1990, Heikkilä & Lindholmin 1995, s.551 mukaan) mukaan noin 6 miljoonaa hehtaaria suopinta-alaa, joka on noin 60 % koko maan suopinta-alasta. Tällä hetkellä Suomen suopinta-alasta noin neljä miljoonaa hehtaaria on ojittamatonta suota, sekin pääosin Pohjois-Suomessa (Suomen ympäristökeskus 2020). Aiemmin suo- ojituksesta maksettiin tukea valtion toimesta metsänomistajalle, joka on sittemmin lopetettu (Rönty 2020). Kuitenkin niin kutsuttuja Kemera-tukia maksetaan yhä esimerkiksi soiden kunnostusojituksesta (Metsäkeskus 2016; Rönty 2020). Metsänomistaja voi saada valtion tukea myös ennallistamistoimenpiteisiin osana metsäluonnon hoitoa (Rönty 2020).

Suo-ojituksen tavoitteena Suomessa on pääasiassa ollut laskea WT:tä, ja siten saattaa hydrologinen tila viljelykasveille tai puustolle suotuisaksi (Heikkilä & Lindholm 1995, s.551). Ojitus on siis sukkession johtamista, jossa suon hydrologiaan aiheutetaan suunniteltu häiriö, joka johtaa ainakin toiveissa tilanteeseen, jossa sukkessio kohti kuivempaa, kangasmaisempaa ekosysteemiä alkaa (Luken 1990, s.17). Metsätalouden kannalta pääasiassa tämä on onnistunut puustoisilla soilla, kuten korvissa, kun avoimilla ojitetuilla soilla puun kasvu on jäänyt usein heikoksi (Heikkilä & Lindholm 1995, s.551). Monet soiden kasvilajit, kuten lettorikko (*Saxifraga hirculus*), lettosara (*Carex heleonastes*) ja kiiltosirppisammal (*Drepanocladus vernicosus*) ovat uhanalaistuneet nopeasti laaja-alaisen ojituksen myötä (Heikkilä & Lindholm 1995, s.552). Ojittamisen myötä ombrotrofiset suot muuttuvat kohti rämemäisiä biotooppeja, kun minerotrofiset suot muuttuvat kohti metsäisiä biotooppeja (Heikkilä & Lindholm 1995, s.552).

Sukkessiolla tarkoitetaan prosessia, jossa kasviyhteisöt muuttuvat ajan myötä (Luken 1990, s.1). Sukkessimallin vanhentunut konsepti on sukkession kliimaksi, jossa ajatellaan, että ajan myötä eliöyhteisö kehittyy tilanteeseen, jossa se on lähes vakaa ja muuttumaton (Gibson 1996, s.135). Kuitenkin tutkimuksen myötä nykypäivänä käsitys on muuttunut niin, että tasapainotilaa ei saavuteta ja eliöyhteisöön vaikuttavat alituisesti esimerkiksi elottomassa ympäristössä tapahtuvat tai populaatioiden luonnolliset vaihtelut, ja ennemminkin pitäisi puhua ”luontaisesta tai historiallisesta vaihtelusta” (Keto-Tokoi & Kuuluvainen 2010, s.17-19; Gibson 1996, s.135). Ikääntyessään kasviyhteisöjen populaatiorakenne voi muuttua ja lajit voivat korvaantua toisilla lajeilla (Luken 1990, s.2). Sukkessioon voi vaikuttaa ja sukkessio voi aiheuttaa muutosta veden, ravinteiden ja valon saatavuudessa (Luken 1990, s.2). Picket et al. (1987) mukaan sukkession yleisiä syitä ovat esimerkiksi: ympäristöjen aiheuttamat muutokset kasvupaikoissa; kasvilajien saatavuus, johon taas vaikuttavat lajien levinneisyys, lisääntymiskyky ja yleisesti resurssit; sekä kasvilajien toimintakyky ko. olosuhteissa, johon taas vaikuttavat lajien ekofysiologia, historia, stressi, kilpailu, muiden lajien inhibitio ja kasvinsyöjäeläinlajit. Luonnossa lajien vaikutussuhteet ovat hyvin monimutkaisia ja moninaisia, ja muutokset ekosysteemin parametreissa, kuten ojituksen tapauksessa vedenpinnantasossa, -vaihtelussa ja virtauksissa voi aiheuttaa arvaamattomia ja peruuttamattomiakin muutoksia ekosysteemien toimintaan.

Ojituksessa suon matalimpaan kohtaan kaivetaan laskuoja, johon yhdistyvät vinosti suon kaltevuuteen nähden kaivetut sarkaojat (Rehell et al. 2013b, s.49). Lisäksi

mineraalimailta tulevat vedet usein katkaistaan suon vaihettumisvyöhykkeelle kaivettuihin niskaojiin (Rehell et al. 2013b, s.49). Vaihettumisvyöhykkeellä tarkoitetaan suon reuna-aluetta, jossa mineraalimaa vähitellen muuttuu suoksi. Onnistuessaan ojitus pitkälti katkaisee veden virtauksen akrotelmassa (Rehell et al. 2013b, s.49). Sen vaikutus on hyvin merkittävä erityisesti minerotrofisilla soilla, joilla veden virtaus ja ympäröiviltä mailta tulevat vedet ovat kasvillisuusrakennetta määrittäviä tekijöitä (Rehell et al. 2013b, s.49; Aapala et al. 2009, s.36). Riippuen suon topografiasta, eri ojilla saattaa olla eri suuruusluokan vaikutukset hydrologiaan: esimerkiksi tiheäkin tasaiselle suolle tehty ojitus saattaa vaikuttaa vähemmän valuma-alueen valuntaan, kuin muutamat jyrkemmälle rinnesuolle tehdyt ojat (Holden et al. 2006). Holden et al. (2006) huomasivat tutkimuksessaan, että WT pysyi tutkimuksen luonnontilaisilla rinnesuokohteilla lähellä suon pintaa ja melko yhtenäisessä syvyydessä. Tutkimuksen ojitetuilla rinnesuokohteilla WT oli syvimmällä heti rinteiden poikkisuunnassa kulkevan ojan alarinteen puolella, kun se oli korkeimmillaan noin 2 m ennen ojaa ylärinteen puolella.

Ojituksen tai muun häiriön aiheuttama vedenpinnan lasku suolla johtaa aiemmin pääosin anaerobisissa olosuhteissa olleen turpeen paljastumiseen ja huokosten täyttymiseen ilmalla, joka taas johtaa aerobisten mikrobien aktiivisuuden lisääntymiseen ja aerobisen hajoamisen kiihtymiseen (Holden et al. 2004). Aerobinen hajoaminen on noin 50 kertaa nopeampaa verrattuna anaerobiseen hajoamiseen (Clymo 1983, Holden et al. 2004, s.105 mukaan). Hiileen sitoutuneet typpi, rikki ja orgaaninen fosfori mineralisoituvat tarjolla olevan hapen vaikutuksesta, eli vapautuvat hajoavasta orgaanisesta turpeesta mineraaleina (Holden et al. 2004, s.105). Mineralisoituneet ravinteet ovat epäorgaanisina ioneina suoraan kasvien hyödynnettävissä, ja ne voivat huuhtoutua valumaveden mukaan. Rehell et al. (2013b, s.49) mukaan kasvava puusto käyttää suuren osan hajotuksessa vapautuvista ravinteista, mutta esimerkiksi Ahtiainen & Huttunen (1999) raportoivat metsän uudisojituksen nostavan vesistön typen, fosforin ja kiintoaineksen kokonaiskuormitusta huomattavasti lyhyellä aikajänteellä. Lisäksi Nieminen et al. (2017) tutkivat 54:än luonnontilaisen suon valuma-aluetta ja 34:ää ojitettua valuma-aluetta, ja huomasivat, että valumavesien ravinnepitoisuudet korreloivat ojituksen iän kanssa. Vaikka valumavesien typpi- ja fosforikonsentraatiot olivat 20-30 vuotta vanhoilla ojituksilla noin luonnontilaisten tasolla, olivat ne yli kaksinkertaisia 60 vuotta sitten ojitetuilla valuma-alueilla verrattuna nuorempiin ojituksiin. Aiemmin on ajateltu, että ojituksen aiheuttama ravinnekuorma on väliaikainen ja palaa luonnontilaisen tasolle vähitellen (Luonnonvarakeskus 2017).

Holden et al. (2004, s.106) mukaan useat tutkimukset ovat havainneet typen ja fosforin pitoisuuksien nousua ja kaliumin pitoisuuden laskua kuivuneen turpeen pintakerroksessa verrattuna luonnontilaiseen turpeeseen. Ainakin typen mineralisoituminen on heterogeenista eri kohteilla ja riippuu turpeen hajoamisnopeuden muutoksesta, johon vaikuttavat lämpötila, pelkistymispotentiaali, pH, hajoamisen vaihe, orgaanisen aineksen laatu, ravinnepitoisuudet, maaveden kemia ja mahdolliset mikrobitoiminnan inhibiittorit (Holden et al. 2004, s.106). Rehell et al. (2013b, s.50) toteavat Metsähallituksen Ojitettujen soiden ennallistamisoppassa uudisojitukselle käytettävän kymmenen vuoden kuorman ominaisarvoja 1,61 kg-P/ha ja 21,1 kg-N/ha. Holden et al. (2004, s.107) summaavat useiden tutkimusten osoittavan ojituksen vaikuttavan valuntaveden laatuun heikentävästi lisäämällä muun muassa ravinteiden huuhtoutumista. Muun muassa ammoniakkin pitoisuuksien on huomattu nousevan valumavesissä ojituksen seurauksena. Myös kaliumin, kalsiumin, magnesiumin, mangaanin, piin, alumiinin ja suspendoituneiden sedimenttien eli kiintoaineiden pitoisuuksien kasvua on havaittu tutkimuksissa. Ojitus myös edistää katotelmaan varastoituneen veden vapautumista ja aiheuttaa sinne varastoituneiden ravinteiden, mineraalien ja metallien huuhtoutumisriskiä (Holden et al. 2004, s.107). Myös kiintoaine huuhtoutuu ojituksen myötä hapettuneesta turpeesta helpommin alempiin vesistöihin ja saattaa aiheuttaa esimerkiksi pohjan liettymistä, ja siten vaelluskalojen elinolosuhteiden heikentymistä otollisten kutusoraikkojen kadotessa lietteen alle (Mattila 2020). Kutuolosuhteet saattavat heikentää entisestään, kun humushapot liukenevat ojitetulta suolta valumavesiin ja laskevat alapuolisten vesistöjen pH:ta (Mattila 2020).

Turve on hyvin huokoista. Luonnontilaisella suolla turve on 90 m-% vettä, ja vettä on 300 V-% verrattuna kiintoaineen määrään. (Hobbs 1986, Holden et al. 2004, s.104 mukaan). Kastuessaan se turpoaa ja vastaavasti kuivuessaan kutistuu (Rezanezhad et al. 2016, s.76). Toisaalta turve muuttuu kuivuessaan usein hydrofobiseksi ja sen alkuperäisen kosteuspitoisuuden palautuminen voi olla mahdotonta (Egglesmann et al. 1993, Holden et al. 2004, s.104 mukaan). Turpeen kuivuessa veden kelluttava vaikutus katoaa (Menberu 2018, s.19), turpeen ylin kerros painuu kasaan ja sen tiheys kasvaa (Holden et al. 2004, s.104). Samalla se painaa kasaan alempaa katotelmaa, jonka tiheys kasvaa myös (Price & Schlotzhauer 1999; Schothorst 1977). Pintakerroksen kuivuminen aiheuttaa siihen negatiivisen hydrologisen paineen ja kapillaari-ilmion myötä alempien kerroksien kosteutta nousee ylempään kerrokseen. Siten koko turvekerros kuivuu ja painuu kasaan, ja turpeen tiheys kasvaa kauttaaltaan (Holden et al. 2004, s.104; Price & Schlotzhauer



1999), huokoinen ylempi akrotelmakerros ohenee ja tiiviimpi, alempi katotelma tiivistyy (Menberu 2018, s.19; Price & Schlotzhauer 1999). Price et al. (2003, s.65) mukaan pääasiassa tiivistymisen aiheuttama vajoaminen turpeessa saattaa olla jopa 3,7 cm/a pian uudisojituksen jälkeen, kun pitemmällä aikavälillä tiivistymisen ja hapettumisen aiheuttama painuminen voi olla 0,3 cm vuodessa. Ajan myötä turpeen tiivistyessä suo menettää diplotelmisen luonteensa (Mustamo et al. 2016, s.408).

Maa-aineksen kykyä pidättää vettä voidaan kuvata termillä ominaissaanto  $S_y$ .  $S_y$  on tyypillisesti korkea turpeelle ja on seurausta sen suuresta huokoisuudesta  $n$ . Päivänen (1973, s.46) havaitsi, että kun turpeen tiheys kasvaa, sen huokoisuus  $n$  pienenee, ja samalla saturoituneen turpeen vesipitoisuus pienenee, riippumatta turpeen laadusta. Ominaisaanto  $S_y$  on vapaan akviferin maa-aineksesta riippuva ominaisuus (Rossi 2019a). Se on yksikötön muuttuja, ja määritellään painovoiman vaikutuksesta vapautuvan veden määrän suhteena veden pinnantason muutokseen (Rossi 2019a). Siis

$$S_y = \frac{V_g}{\Delta W T}, \quad (1)$$

missä  $S_y$  on ominaissaanto,

$V_g$  on painovoimaisesti poistuvan veden tilavuus [mm] ja

$\Delta W T$  on veden pinnantason muutos [mm].

Vapautuva vesi sijaitsee pääasiassa maa-aineksen huokosissa, ja siten  $S_y$  on verrannollinen maa-aineksen huokoisuuteen  $n$  (Rossi 2019a). Mentäessä syvemmälle turvekerroksessa, sen tiheys kasvaa, huokoisuus pienenee, ja  $S_y$  muuttuu syvyyden  $h$  funktiona. Ojituksen myötä turvekerroksen tiheyden kasvaessa  $S_y$  pienenee, mikä johtaa suurempaan vedenpinnan tason vaihteluun WTF (Mustamo et al. 2016, s.408; Kettridge et al. 2015, s.1; Menberu 2018, s.19; Price & Schlotzhauer 1999). Luonnontilaisella suolla WTF on melko vähäistä turpeen suuren huokoisuuden, ja siten suuren  $S_y$ :n ansiosta (Rocheffort & Lode 2006, s.395).

Ojituksen myötä veden virtaus turvekerroksissa muuttuu. Holden et al. (2006) seurasivat tutkimuksessaan kahden luonnontilaisen ja kahden kuivatetun suon valunnan muutoksia Pohjois-Penniineillä Iso-Britanniassa, ja huomasivat, että kuivatetuilla soilla syvemmällä, kuin 10 cm syvyydessä turpeessa tapahtuva valunta käsitti 23 % kokonaisvalunnasta, kun luonnontilaisilla soilla se käsitti alle 1 % valunnasta ja

pintavalunta vallitsi. Holden et al. (2004, s.104) summaavat tutkimuksessaan aiempia tutkimuksia ojituksen hydrologisista vaikutuksista. Saavutettu vedenpinnan tason lasku ojituksella saa lyhyellä jänniteellä aikaan väliaikaisen varaston kasvua valuma-alueella ja vähentää valuntavasteen herkkyyttä sadetapahtumille, ja siten voi vähentää valunnan ääriarvoja. Pitkässä aikajänteessä, kun turve hajoaa, valuma-alue saattaa kuitenkin vastata sadetapahtumiin jyrkemmillä valunnan ääriarvoilla, ja siten kuivuuden ja tulvan riski kasvaa (Holden et al. 2004, s.104; Mattila 2020). Turpeen hajotessa katoaa myös kuivatuksen myötä kasvanut potentiaalinen väliaikainen varasto valuma-alueella (Holden et al. 2004, s.104). Kun kesien kuivaan aikaan alivalumat pienentyvät, virtavesien lämpötilat nousevat, mikä osaltaan heikentää viileissä ja hapekkaissa vesissä elävien eliöiden elinmahdollisuuksia (Mattila 2020).

Menberu (2018, s.21) toteaa väitöskirjassaan, että vaikka ojituksen vaikutuksista hydrologiaan on tehty useita tutkimuksia, ovat niiden tulokset ristiriidassa erityisesti väliaikaiseen varastoon ja valunnan ääriarvoihin liittyen. Menberun (2018, s.20) ja Holden et al. (2004, s.102-103) mielestä tämä saattaa johtua soiden kompleksisesta luonteesta: eri kasvien jäännöksistä muodostuneilla turpeilla on erilaiset ominaisuudet ja suot itsessään ovat erilaisia ominaisuuksiltaan: esimerkiksi suon pinnan vietto on erilainen erilaisilla soilla, kasvillisuuspeite vaihtelee ja suot sijaitsevat erilaisissa paikoissa valuma-alueella, erilaisten maiden ympäröimänä, ja laskevat vetensä erilaisiin vesistöihin. Metsäojitus lisää valuntaa valuma-alueella, Rehell et al. (2013b, s. 49) mukaan, ensin suon vesivaraston tyhjenemisen myötä välittömästi ojituksen jälkeen. Vesivaraston tyhjenemisen vaikutus laimenee usein muutamassa vuodessa (Rehell et al. 2013b, s. 49). Pitkällä aikavälillä tärkeämpi muutos vesitaloudessa on evaporaation väheneminen soilta, joka voi olla Rehell et al. (2013b, s.49) jopa satoja millimetrejä vuodessa. Evaporaatiolla tarkoitetaan haihduntaa. Myöhemmin vähentynyt evaporaatio voi puuston kasvaessa korvaantua transpiraatiolla, eli puiden soluhengityksen tuottamalla haihdunnalla. Myös useimmat Menberun (2018, s.21) kertaamat tutkimukset raportoivat vuosittaisen valunnan määrän kasvua. Ojitus kasvattaa myös alivalumia voimakkaasti heti kuivatuksen jälkeen, mutta myös myöhemmin, erityisesti silloin, kun ojitusalueella on pohjavesimuodostuma, jonka pintaa ojitus alentaa (Rehell et al. 2013b, s.49-50).

## 2.5 Soiden ennallistaminen

### Ennallistamisen periaate ja vaikutukset

Ennallistamisen pääasiallisena tavoitteena on biodiversiteetin eli luonnon monimuotoisuuden säilyttäminen (Joosten et al. 2017, s. 5; Aapala et al. 2013b, s.19). Ihmisen toiminnan vaikutuksesta muuttuneiden suoalueiden ennallistamisen tavoitteena on saada alulle ekologinen sukkessio, jossa suoluonto palautuu kohti sen luonnollista tilaa. Ennallistamistoimet pyrkivät siis ojittamalla kuivatetuilla suoalueilla ensisijaisesti palauttamaan jo kertaalleen häirityn ekosysteemin hydrologisen tilan uudella suunnitellulla häiriöllä (Luken 1990, s.17), ja siten vaikuttamaan soiden funktionaalisten ja rakenteellisten ominaisuuksien palautumiseen, kuten turpeen kertymiseen ja suokasvillisuuden ja suoluontotyyppien esiintymiseen ennallistetulla alueella (Aapala et al. 2012, s.197). Käytännössä tämä tarkoittaa ojituksen patoamista tai tukkimista, veden virtauksen hidastamista ja vesien ohjaamista halutuille alueille (Vesterinen et al. 2013, s.138; Rehell et al. 2013d, s.121; Aapala et al. 2009, s. 36). Käytännön ennallistaminen tulisi aina suunnitella hyvin, sillä eri ennallistamiskohteet ovat hydrologialtaan erilaisia ja ojitukset ovat aiheuttaneet niihin eriasteisia häiriöitä (esim. Rehell et al. 2013d; Aapala et al. 2009, s. 36). Esimerkiksi minerotrofisilla soilla ja aapasuokomplekseilla niskaojien täyttö on tärkeä keino palauttaa mineraalimailta virtaavia vesiä ennallistettaville kohteille (Heikkilä & Lindholm 1995, s.554). On tärkeää huomata, että ennallistamistoimilla voidaan aiheuttaa myös negatiivisia vaikutuksia ennallistamiskohteen ympäristössä, esimerkiksi lähistön metsätalousalueilla tai valuma-alueella olevissa herkissä, lajistoltaan arvokkaissa vesistöissä (Heikkilä & Lindholm 1995, s.555).

Useissa tutkimuksissa on tutkittu ennallistamistoimien vaikutusta ennallistamiskohteiden ja valuma-alueiden hydrologiaan Suomessa (esim. Menberu 2018; Menberu et al. 2016; Haapalehto et al. 2014; Sallantaus & Koskinen 2012). Sallantaus & Koskinen (2012) tutkivat artikkelissaan ravinteiden huuhtoutumista ennallistetuilta soilta, ja huomasivat tutkimuskohteillaan ennallistamistoimien aiheuttaneen valumaveden laadun heikentymistä lyhyellä aikavälillä. Menberu et al. (2016) tutkivat artikkelissaan 24:ää ojitettua suota Suomessa ja ennallistamisen aiheuttamaa muutosta niiden vesitaloudessa, sekä vertasivat niitä 19:ään luonnontilaiseen suokohteeseen. He kehittivät ja käyttivät useita erilaisia tapoja vesitalouden ennallistamisen onnistumisen arviointiin, ja totesivat ojien tukkimisen ja patojen rakentamisen palauttaneen soiden WTD:n, WT:n vaihtelun WTF, WT:n muutosnopeuden ja sadetapahtuman aiheuttaman varastonmuutoksen SG

(engl. *storage gain*) luonnontilaisen kaltaiseksi useimmissa tapauksissa. Menberu et al. (2016) määrittelevät SG:n artikkelissaan nk. *water-table fluctuation method*'n (Healy & Cook, 2002) avulla, jossa

$$SG = S_y(h) * \Delta WT, \quad (2)$$

missä  $S_y(h)$  on WT:n syvyydestä riippuva ominaisaanto,

$\Delta WT$  on sadetapahtuman aiheuttama veden pinnantason muutos [mm].

Ojituksen ja sen aiheuttamien muutosten laajuudet ja ojituksen ikä vaikuttavat ekosysteemin palautumisen nopeuteen: mitä laajempia ja pidemmälle edenneitä muutokset ovat verrattuna alkuperäisen ekosysteemin tilaan, sitä kauemmin ekosysteemin palautuminen kestää ennallistamisen jälkeen (Rocheft & Lode 2006, s.381). Turpeen fysikaaliset ominaisuudet ovat muuttuneet kuivatusojituksen myötä, ja siten ennallistamisen myötä luonnontilaisen kaltaisen vesitalouden saavuttaminen voi olla monimutkaista (Rocheft & Lode 2006, s.394). Erityisesti palautumiseen vaikuttavat turpeen huokoisuus  $n$  ja hydraulinen johtavuus  $K$ , jotka vaikuttavat veden virtaamiseen turpeessa (Rocheft & Lode 2006, s.395). Rocheft & Loden (2006, s.381) mukaan monimutkaisten suokompleksien ennallistaminen alkuperäiseen tilaan voi olla käytännössä mahdotonta, ja sitä rajoittavat usein esimerkiksi sosioekonomiset ja ympäristötekijät. Tällaisia voivat olla esimerkiksi ilmasto, ympäröivän maan maankäyttö tai riittämätön tieto alkuperäisen suokompleksin tilasta (Rocheft & Lode 2006, s.381). Rocheft & Lode (2006, s.381-382) määrittelevätkin soiden ennallistamisen päätavoitteeksi ”heikentyneiden tai tuhoutuneiden soiden palauttamisen kosteikkoekosysteemeiksi”, jotka ajan myötä muuttuvat turvetta kerryttäviksi ekosysteemeiksi, jotka suosivat biodiversiteettiä ja vastustavat biologista invaasiota, eli vastustavat uusien, esimerkiksi kangasmaisemman luontotyypin lajien siirtymistä alueelle suurina joukkoina (Smithsonian Environmental Research Center 2020).

Joosten et al. (2017, s.5.) toteavat teoksessaan suoluonnon luokittelemisen olevan konfliktissa ennallistamisen tavoitteen kanssa, sillä luokittelu yksinkertaistaa suoluonnon diversiteettiä. Luokittelu on kuitenkin välttämätöntä, jotta luontotyyppien diversiteettiä voidaan arvioida. Suoluontotyyppistä riippuen ennallistamistoimet pyrkivät palauttamaan sen alkuperäisen kasvillisuuspeitteen, joka usein boreaalisella vyöhykkeellä on rahkasammaleiden vallitsemaa (Rocheft & Lode 2006, s.382).

Sukcession aikaansaamiseksi kohti luonnollista tilaa tulisi suolla olla siis jäljellä suoekosysteemin kasvilajeja tai kasvien siementaimia tai osia, jotta alkuperäisen kaltainen kasvilajisto voi alkaa kasvaa sopivien olosuhteiden palaututtua. Jos näin ei ole, tulisi kasvillisuudella olla mahdollisuus levitä ennallistettavan alueen ulkopuolelta. Joissakin ennallistamistapauksissa voidaan joutua tekemään kasvilajien siirtoistutuksia pois ennallistamistoimien tieltä, esimerkiksi pois tukittavien ojien penkoilta (Eeronheimo et al. 2013, s.132). Usein ennallistettavien soiden tapauksessa joudutaan myös poistamaan puustoa, jotta luonnolliset valo-, ravinne ja kosteusolosuhteet saavutetaan, vaikka vedenpinnan tason nosto johtaakin usein puulajien heikompaan selviytymiseen (Eeronheimo et al. 2013, s.132, Luken 1990, s.126). Aapala et al. (2009, s. 36) mukaan luontaisen kaltaisen sukcession palautuminen voi kestää pitkään, mutta lajiston muutos alkaa usein jo muutamassa vuodessa.

### **Ennallistamisen onnistumisen seuranta**

Society for Ecological Restoration International Science & Policy Working Group (SER) (2004, s.3) esittää pohjustuksessaan yhdeksän ominaisuutta, jotka ennallistetun ekosysteemin tulisi täyttää, jotta ennallistamisen voidaan katsoa onnistuneen:

1. samankaltainen diversiteetti kuin referenssikohteella, eli lajisto ja sen jakautuminen on samankaltainen;
2. alkuperäisten lajien esiintyminen;
3. ekosysteemin kehittymisen ja stabiliteetin kannalta tärkeiden funktionaalisten ryhmien esiintyminen;
4. ekosysteemin fyysisen ympäristön mahdollisuus ylläpitää kehittymisen ja stabiliteetin kannalta tärkeitä populaatioita;
5. ekosysteemi toimii häiriöttä, niin kuin sen kuuluu sukkessiotasollaan;
6. ekosysteemi on integroitunut maisemaansa asiaankuuluvalla tavalla;
7. ympäristön mahdolliset uhat ekosysteemin eheydelle ja terveydelle on eliminoitu;
8. ekosysteemi on vastustuskykyinen ja
9. ekosysteemi on itseään ylläpitävä.

Nämä ominaisuudet voidaan jakaa yhä kolmeen kategoriaan: diversiteetti, kasvillisuuden rakenne ja ekologiset prosessit (Ruiz-Jaen & Aide, 2005 s.569). Ruiz-Jaen & Aide (2005, s.569) suosittelevat koontiartikkelissaan ennallistamisen onnistumisen arvioinnissa käytettäväksi vähintään kahta muuttujaa jokaisesta kategoriasta. Heidän mielestään olisi

myös syytä käyttää vähintään kahta luonnontilaista vertailukohdetta seurannassa luonnollisen vaihtelun huomioimiseksi. Lisäksi SER:n (2004, s.4) pohjustuksessa todetaan, että lueteltujen ominaisuuksien lisäksi voidaan arvioida muitakin ekosysteemin ominaisuuksia, jos ne asetetaan ennallistamisprojektin tavoitteiksi. Esimerkkeinä annetaan ekosysteemipalvelut ja ekosysteemin ennallistaminen harvinaisten tai uhanalaisten lajien elinympäristöksi. Huomattavaa kuitenkin on, että ennallistamisen tavoitteet tulee ennallistamissuunnitelmaa tehtäessä määritellä riittävän tarkasti ja laajasti, jotta niiden toteutumista voidaan ylipäätään arvioida (Aapala et al. 2009, s.38). Kun suon luonnollisen vesitalouden palauttaminen on ennallistamisen pääasiallisen tavoitteena, tulisi sitä ennallistuskohteella arvioida jo ennen ennallistamista, sillä se on pohjana kaikille ennallistamisen tuleville hydrologisille seurannoille (Aapala et al. 2009, s.38). Usein tähän nk. hydrologiseen analyysiin käytetään uusia ja vanhoja ilmakuvia, ja siihen voidaan sisällyttää myös esimerkiksi analyysejä vesikemiasta ja vaaituksista, jos ennallistamisella voi olla laajoja vaikutuksia ympäröiviin alueisiin, tai sen mahdolliset vaikutukset ovat muuten epäselviä (Aapala et al. 2009, s.38).

Metsähallituksen luontopalvelujen perustamassa soiden seurantaverkostossa ennallistettujen soiden seuranta tehdään kolmella eri tasolla: yleisluontoisella tasolla eli nk. hoitoseurannalla, hydrologisella seurannalla ja monimuotoisuusseurannalla (Penttinen et al. 2013 s.179; Aapala et al. 2009, s.40). Ennallistamisen seurannan ensimmäinen taso on yleisluontoinen seuranta, joka tehdään kaikilla Metsähallituksen ennallistamilla kohteilla vähintään kahdesti ensimmäisen kymmenen vuoden aikana ennallistamisen jälkeen. Yleisluontoinen seuranta on subjektiivinen, näönvarainen ja kvalitatiivinen. Siinä arvioidaan lähinnä näönvaraisesti ennallistamiskohteen hydrologisia ominaisuuksia ja kasvillisuutta, eli onko kasvillisuuden sukkessio oikeansuuntaista ja hydrologinen tila sen kaltainen, että sukkessio voi jatkua kohti luonnontilaisen kaltaista ympäristöä. Ennallistamisen yleisluontoisen seurannan päätarkoituksena on varmistaa ennallistamistoimenpiteiden tarkoituksenmukaisuus, tarkkuus ja ennallistamissuknessioprosessi, sekä löytää mahdolliset puutteet ja ongelmat toimenpiteissä mahdollisimman aikaisessa vaiheessa. (Penttinen et al. 2013, s.179; Aapala et al. 2012, s.198-199; Aapala et al. 2009)

Ennallistamissuunnitelmassa eriteltyjen ennallistamisen kannalta kriittisimpien alueiden tarkastelu on ensimmäisen yleisluontoisen teknisen seurannan keskiössä. Ensimmäisinä vuosina ennallistamisen jälkeen seurataan lähinnä siis ennallistamistöiden teknistä

onnistumista ja vesien leviämistä suolle, ja myöhemmin arvioidaan kasvillisuuden muutoksia, kun ne alkavat suolla näkyä (Aapala et al. 2009, s. 41). Ensimmäiset tarkastelut voidaan tehdä vain osalle suosta tai koko ennallistetulle alueelle, mutta kymmenvuotisseuranta tehdään laajemmin suokuviokohtaisena (Aapala et al. 2009, s. 41). Aapalan et al. (2012) mukaan oletus on, että kymmenessä vuodessa suurimmat ennallistamistoimenpiteiden aiheuttamat häiriöt ovat vaimentuneet ja ennallistamisen aiheuttama sukkessio on niin pitkällä, että on mahdollista arvioida, onko ennallistaminen onnistunut, ovatko mahdolliset ennallistamisen lisätoimenpiteet ja myöhempi seuranta tarpeellisia.

Käytännössä Suomessa Metsähallitus tekee ennallistamisen hydrologista seurantaan jatkuvatoimisten vedenpinnan korkeutta mittaavien tiedonkeruulaitteiden eli loggerien avulla, sekä kolme kertaa maastokauden (toukokuusta syyskuuhun) aikana otettavien vesinäytteiden avulla suo- ja valumaseurantakohteilla (Penttinen et al. 2013, s.180). Lisäksi osalla kohteista mitataan mittapadon ja loggerin avulla valuntaa suolta. Mittapato on pato, jossa on standardoitu v:n muotoinen aukko, jonka läpi virtaavan veden korkeuden mittaamalla voidaan arvioida valuntaa (Hyvärinen & Aapala 2009, Liite 12. 1(5)). Patokohteilla seuranta tehdään myös maastokauden ulkopuolella. Automaattiset loggerit tallentavat, kuinka suuri kerros vettä loggerikaivossa on loggerin sensorin yläpuolella. Kun tiedetään loggerin syvyys kaivossa, voidaan mittauksista saada selville WT:n vaihtelu pisteessä mittauskauden aikana. Soilla WT:n vaihtelua voidaan verrata luonnontilaisen vertailukohteen vastaavaan, ja siten tutkia, onko ennallistetun kohteen hydrologia samankaltaista luonnontilaisen kanssa. Loggereilla saatavat mittaukset ovat ajallisesti kattavia mittauskaudellaan, sillä loggerit voidaan usein asettaa tekemään mittauksia tarkalla ajallisella resoluutiolla. Loggerin tuottama mittausaineisto on pistemäistä, joten yksittäisillä loggerikaivoilla tehdyt mittaukset antavat spatiaalisesti suppean kuvan usein hyvinkin laajojen ja monimuotoisten soiden hydrologisesta tilasta. Hydrologisen seurannan lisäksi Metsähallitus tekee monimuotoisuusseurantaan, jossa tutkitaan muutoksia lajistoissa ja niiden runsaussuhteissa (Penttinen et al. 2013, s.180). Käytännössä seurantaan on tehty soilla kasvilajien, päiväperhosten, sudenkorentojen ja lintujen osalta, mutta Penttisen et al. (2013, s.180) mukaan seuranta olisi syytä laajentaa muihinkin selkärangattomiin, kuten hämähäkkeihin, muurahaisiin ja pikkuperhosiin, joissa on runsaasti pääasiassa tai pelkästään soilla esiintyviä lajeja.

Menberu et al. (2016) laskivat tutkimuksessaan WTD:n vaihteluvälit, joilla turvetta muodostavat kasvilajit menestyvät erilaisilla soilla. Laskentaan käytettiin kymmentä 1 m<sup>2</sup> kasvillisuusruutua luonnontilaisilta soilta ja niillä esiintyvien turvetta tuottavien kasvilajien peittävyksiä. Tämän jälkeen laskettiin, kuinka suuren osan ajasta WTD oli tutkimuskohteilla ko. vaihteluvälillä, kuinka suuren osan ajasta sen ulkopuolella, ja kasvilajien peittävyysien perusteella määritettiin optimaaliset WTD:n vaihteluvälit lajien menestymiselle. Vaihteluvälit pyöristettiin tasalukuihin niin, että rämeillä ja korvissa (engl. *spruce mires*, *pine mires*) optimaaliseksi katsottiin 0 cm < WTD < -30 cm, jossa 0 cm kuvaa suon pinnan tasoa ja -30 cm on suon pinnan alapuolella. Avosoille (engl. *fens*) optimaaliseksi tilanteeksi katsottiin, kun WTD on välillä 0 cm < WTD < -20 cm.

### Hydrologia LIFE

Ennallistamista on tehty Suomessa pääasiassa suojelualueilla vuodesta 1987 lähtien (Aapala et al. 2012, s.197). Ennallistamisia on tehty vuoteen 2019 mennessä noin 30 000 ha (Rönty 2020). Aluksi ennallistettujen alueiden laajuudet olivat vaatimattomia, mutta Euroopan Unionin LIFE-hankkeiden myötä pinta-alat ovat laajentuneet ja ennallistamismenetelmät ja ennallistamisen työkalut parantuneet (Aapala et al. 2012, s.197). Hydrologia LIFE -projekti (LIFE16 NAT/FI/000583) on osa LIFE-ohjelmaa, joka on ollut Euroopan Unionin ympäristö- ja ilmastotoimien rahoitusväline pian jo kolmenkymmenen vuoden ajan (European Commission 2020c). LIFE-ohjelmaa edelsi 1980-luvun puolivälistä vuoteen 1991 *Action Communautaire pour l'Environnement* eli ACE ympäristöprojektien rahoitusvälineenä. Erityisesti se keskittyi kolmeen eri alaan, joita olivat uusien puhtaiden teknologioiden kehittäminen, ympäristön monitorointi- ja mittaustekniikoiden kehittäminen, sekä erityisesti EU:lle tärkeiden uhanalaisten lajien elinympäristöjen suojelu, joka laajentui myöhemmin myös saastuneiden, aavikoituneiden, palojen vahingoittamien ja erodoituneiden alueiden ennallistamiseen. Yhtäaikaaisesti ACE:n kanssa toimivat myös MEDSPA- ja NORDSPA -ohjelmat, joiden molempien alaan kuului ennallistamisprojekteja. (European Commission 2020b)

Vuonna 1991, kun ACE, MEDSPA ja NORDSPA -ohjelmat päättyivät, otettiin käyttöön lyhytaikaiseksi jäänyt *Actions by the EU for Nature* eli ACNAT-rahasto, jonka tavoitteena oli säilyttää jatkumo EU:n lintudirektiivin mukaisissa toimissa ja lisäksi ohjata rahoitusta muiden uhanalaisten lajien ja elinympäristöjen suojelemiseen. Pian, jo vuonna 1992 ACNAT:n syrjäytti kattavampi LIFE-ympäristörahasto. Ensimmäisen LIFE I -rahoituskauden tavoitteena oli vastata ympäristöongelmiin rahoittamalla



projekteja viidellä eri tasolla: kestävän kehityksen ja ympäristön laadun edistäminen; elinympäristöjen ja luonnon suojelu; hallinnolliset rakenteet ja ympäristöpalvelut; opetus, koulutus ja informaatio; sekä toimet EU:n ulkopuolisissa maissa. Sitten eri rahoituskausien myötä ohjelman budjetti on kasvanut ja soveltamisala mukautunut ajan tarpeisiin. LIFE 2014-2020 jakautuu kahteen alaohjelmaan, joista toinen rahoittaa ympäristö- ja toinen ilmastotoimia. Tulevalle LIFE 2021-27 rahoituskaudelle Euroopan Komissio on esittänyt 5,4 miljardin euron budjettia, kun tämänhetkisen kauden 2014-2020 budjetti on kaksi miljardia euroa alhaisempi, ja ensimmäisen, kolmivuotisen LIFE I rahoituskauden budjetti oli vain 400 miljoonaa euroa. Aihealueen tärkeys on mitä ilmeisimmin kausi kaudelta korostunut ja rahoitusta ohjataan sen piiriin aiempaa enemmän. Tuleva LIFE 2021-27 jakautuu neljään alakategoriaan, jotka ovat luonto ja biodiversiteetti, kiertotalous ja elämänlaatu, ilmastomuutoksen lieventäminen ja siihen sopeutuminen, sekä siirtyminen puhtaaseen energiaan. (European Commission 2020b)

Hydrologia LIFE -projekti sijoittuu ajanjaksolle 2017-2023. Projektia koordinoi Metsähallitus, ja projektissa mukana olevia tahoja ovat muiden muassa Oulun, Turun ja Jyväskylän yliopistot, Keski-Suomen ja Pohjois-Savon elinkeino-, liikenne- ja ympäristökeskukset eli ELY-keskukset, Luonnonvarakeskus LUKE, Suomen Metsäkeskus, Metsähallituksen tytäryhtiö Metsätalous Oy, sekä Tapio Oy. Projektin noin 9 miljoonan euron budjetista 60 % eli runsaat 5,3 miljoonaa euroa on LIFE-hankerahoitusta Euroopan Unionilta. Loput rahoituksesta on saatu Pohjois-Karjalan ELY-keskukselta ja Suomen Ympäristöministeriöltä. (European Commission Environment DG 2020)

Projekti pyrkii lyhyesti ”kosteikkojen hydrologisen eheyden palauttamiseen Suomessa”, ja projektin vaikutusalaan kuuluu 103 suo-, puro- ja lintuvesikohdetta Natura 2000 -alueilla (Ruusunen 2020; Metsähallitus 2020; European Commission Environment DG 2020). Kohteet ovat SCI (engl. *Sites of Community Importance*) ja SPA (engl. *Special Protection Area*) -alueita (European Commission Environment DG 2020; European Commission 2020a). Natura 2000 on Euroopan Unionin luontodirektiivissä määriteltyjen luontotyyppien ja lajien turvaamiseen pyrkivä verkosto. EU velvoittaa jäsenmaitaan ehdottamaan sopivia alueita Natura 2000 -verkostoon, ja ehdotuksen jälkeen alue saa SCI-statusen (Ympäristöministeriö 2019; European Commission 2020a). Euroopan Komissio arvioi Euroopan ympäristökeskuksen avustuksella ehdotettujen alueiden soveltuvuuden, hyväksyy alueet, ja jäsenmaa määrittelee hyväksytyt alueet erityisten

suojelutoimien alueiksi (engl. *Special Area of Conservation*) eli SAC-alueiksi (Ympäristöministeriö 2019; European Commission 2020a). Suomessa vuonna 2019 SAC-alueita oli Natura 2000 -alueiden noin 5 miljoonasta hehtaarista noin 4,8 miljoonaa hehtaaria, joka kattaa 12,4 % koko maan pinta-alasta. SAC-alueilla toteutetaan suojelutoimenpiteitä niin, että alueiden edustamien luontotyyppien ja niillä elävien lajien elinvoimaisuus turvataan. (Ympäristöministeriö 2019)

Hydrologia LIFE -projektissa voimakkaasti uhanalaistuneen suoluonnon suojelutoimenpiteitä ovat esimerkiksi aiemmin ojittamalla kuivatettujen soiden ennallistaminen sekä valuma-alueiden vesien palauttaminen kuivuneille soille ympäristössä olevien ojien kunnostuksen yhteydessä (Joensuu 2020; Metsähallitus 2020). Ennallistamista projektissa tehdään 5239 hehtaaria 95:llä kohteella, joista vuoden 2019 loppuun mennessä oli ennallistettu noin 1000 ha (European Commission 2020a; Ruusunen 2020; Metsähallitus 2020). Puiden poistoja tehdään 1321,5 hehtaarilla suoalueiden ennallistamisen mahdollistamiseksi (European Commission 2020a). Lisäksi projektissa kunnostetaan 34 km puroja ja 479 ha umpeen kasvavia lampia lintuvesistöiksi (Ruusunen 2020).

## 2.6 UAS

Ilmasta käsin tehtävä mittaaminen ja kuvantaminen niin kutsutuilla UAS-laitteistoilla (engl. *Unmanned Aircraft System*) on yleistynyt viime vuosina. Sitä myötä ne ovat myös halventuneet ja tulleet tavallisen kuluttajan saataville, ja laitteistojen odotetaan kehittyvän ja hintojen yhä halventuvan kysynnän kasvaessa (Manfreda et al. 2018, s.4). UAS-laitteistoilla tarkoitetaan niin kutsuttuja droneja eli UAV-laitteita (engl. *Unmanned Aerial Vehicle*), eli miehittämättömiä ilma-aluksia, ja niiden ohjaussysteemejä (Jeziorska 2019, s.4). UAS-laitteistoja on alettu hyödyntää tutkimuksessa viime vuosina lentokoneista ja helikoptereista tehdyn ilmakuvauksen ja satelliittikuvauksen rinnalla (Jeziorska 2019). UAS-laitteistojen etuna on pienten, alle 20 ha alojen kuvauksen aika- ja kustannustehokkuus verrattuna perinteisiin laitteistoihin (Matese et al. 2015; Jeziorska 2019 mukaan). UAS-laitteistot tarjoavat lähes reaaliaikaista kuvantamista erittäin tarkalla spatiaalisella ja ajallisella resoluutiolla (Manfreda et al. 2018, s.3). Kun esimerkiksi satelliittikuvantamisen pikselikoko voi olla 0,5 m luokkaa, UAS-kuvantamisella on mahdollista tuottaa alle senttimetriluokan resoluutiotarkkuuden ilmakuvia (Manfreda et al. 2018, s.2-3). Ajallista resoluutiota eli mittausten aikaväliä UAS-kuvauksessa

rajoittavat vain lentokertojen lukumäärä ja pituus sekä laitteiden sähköntarve (Manfreda et al. 2018, s.3). Lisäksi matalasta lentokorkeudesta johtuen UAS-laitteistot toimivat myös pilvisissä ja sumuisissa olosuhteissa tietyin rajoituksin, kun kyseisissä olosuhteissa satelliittikuvaus ja miehitettyjen lentoalusten kuvaukset eivät välttämättä onnistuisi (Manfreda et al. 2018, s. 3).

Manfreda et al. (2018, s.3) toteavat artikkelissaan, että ympäristöprosessit ovat hyvin herkästi vaihtelevia, joten UAS-kuvaus sopii korkean spatiaalisen ja ajallisen resoluution ansiosta erityisen hyvin esimerkiksi hydrologian monitorointiin. Ympäristötiede olikin ensimmäisiä UAS-teknologian hyödyntäjiä siviiliympäristössä (Manfreda et al. 2018, s.3). Jo pelkkä ennallistettavien alueiden ja ennallistamistoimien ilmakuvaaminen lisää työskentelyn läpinäkyvyyttä, kun dokumentointi tehdään hyvin. Lisäksi esimerkiksi vuosittainen tai useammin tehty kuvaus mahdollistaa alueen kehityksen vertailun visuaalisesti, laaja-alaisesti ja parantaa ennallistamisen seurannan objektiivisuutta. Manfreda et al. (2018, s.3) toteavat Singh & Frazierin (2018) korostavan meta-analyysissään UAS-julkaistujen artikkelien prosessointitekniikoiden moninaisuutta ja kuvantamis- ja prosessointitekniikoiden harmonisoinnin ja standardisoinnin tarvetta.

UAS:lla otettujen kuvien ominaisuuksiin vaikuttavat merkittävästi valo- ja sääolosuhteet. Esimerkiksi kova tuuli kuvattaessa ja liian suuri lentonopeus saattaa vaikuttaa kuvien laatuun lehvästön liikkumisen takia (Jensen & Mathews 2016 ja Zainuddin et al. 2016, Lovitt et al. 2017, s.2 mukaan). Tuulenpuuska saattaa liikauttaa UAV:tä tai lehvästöä juuri kuvanottohetkellä odottamattomasti aiheuttaen epäterävyyttä kuvaan. Samoin liian suuri lentonopeus yhdistettynä liian heikkojen valo-olosuhteiden takia käytettyyn pitkään valotusaikaan saatata aiheuttaa liike-epäterävyyttä kuviin. Jos valo-olosuhteissa tapahtuu suuria muutoksia kuvauksen aikana, saattaa osasta kuvista tulla erilaisia esimerkiksi kontrastin tai väritasapainon suhteen. Tästä syystä paras kuvaussää olisi tasaisen pilvinen tyyni pouta (Ikkala 2019), jolloin kovia varjoja ei liiaksi esiinny, valon ja varjon väritasapaino olisi mahdollisimman samankaltainen eikä tuuli aiheuttaisi epäterävyyttä kuviin. Esimerkiksi Lovitt et al. (2017) käyttivät tutkimuksessaan kahtena perättäisenä päivänä samasta alueesta otettuja kuvia, suurten kontrastien eliminoimiseksi. Ensimmäiset kuvat oli otettu myöhäisellä iltapäivällä ja toiset aamupäivällä, kun molempina kuvauspäivinä oli kirkas ja aurinkoinen sää.

Kun ennallistamistoimien tavoitteena on palauttaa luonnontilaisen kaltainen vesitalous suolla, ennallistamistoimenpiteiden vaikutuksia voidaan arvioida sitä paremmin mitä tarkempi korkeusmalli kohteesta on (Rehell et al. 2013c, s.128). Pintamallin avulla voidaan arvioida esimerkiksi suon pinnan nousua, puuston tilavuuden muutosta, ennallistamistoimenpiteiden riittävyyttä ja niiden aiheuttamia WT:n ja virtauksien muutoksia (Rehell et al. 2013c, s.128). Perinteisiä maastomittausmenetelmiä korkeusmallien tuottamiseksi ovat vaaitus, tasolasermittaus, GPS-laitteet ja takymetri (Rehell et al. 2013c s.128-129). Kaikki nämä maastomittausmenetelmät perustuvat ihmisen tekemiin pistemittauksiin ko. laitteiden avustuksella, ja ovatkin hyvin työläitä ja paikoin hankalia tai mahdottomia soiden hankalakulkuisuuden ja vaarallisuuden takia. Maastomittausmenetelmien lisäksi pintamallin tuottamiseen käytetään miehitettyihin lentokoneisiin liitettäviä laserkeilaimia, joilla kuvannetusta alueesta voidaan tuottaa pistepilvimalli, jossa jokaiselle pisteen tietoihin on tallennettu sen x-, y- ja z- koordinaatti (Rehell et al. 2013c s.130).

Sensoriteknikan kehityksen myötä on UAS-laitteisiinkin tarjolla muun muassa multispektri-, hyperspektri- ja LiDAR-kuvantamissensoreita tavallisten kameroiden lisäksi (Manfreda et al. 2018, s.4). Tavallinen näkyvän valon kamera tallentaa pinnoista heijastuvat RGB-aallonpituudet (engl. *Red Green Blue*) eli näkyvän valon aallonpituudet: se siis imitoi ihmissilmää (Ikkala 2019). Multispektrikamera kuvaa näkyvän valon aallonpituuksien lisäksi NIR-säteilyä (engl. *Near-infrared*) ja Red Edge -säteilyä, hyperspektrikamera sitäkin laajempaa spektrialuetta (Ikkala 2019). Kun tavallisemmat RGB-, NIR ja multispektrikamerat tallentavat pintojen heijastamaa tai lähettämää säteilyä, LiDAR taas lähettää tyypillisesti NIR-aallonpituusalueen lasersäteen tai batymetrisissä sovelluksissa vihreän valon laserin ja tallentaa pintojen palauttaman säteen heijastuksen (National Ocean Service 2020). LiDAR on siis nk. aktiivinen tekniikka, kun edeltävät ovat passiivisia tekniikoita. LiDAR-tekniikka läpäisee paremmin lehvästöä ja siten sillä on mahdollista tuottaa luotettavampia pintamalleja, kun kyseessä on tiheän kasvillisuuden alue (Lovitt et al. 2017). Näkyvän valon kuvista on kuitenkin mahdollista tuottaa tiheämpiä pistepilviä (Lovitt et al. 2017). Tämä saattaa parantaa kuvista tuotettujen pintamallien luotettavuutta erityisesti alueilla, joilla on kompleksista pienen skaalan topografista vaihtelua, kuten soilla yleensä on.

Kamera kuvaa tietyn kokoisen alan tietystä pisteestä, ja samat objektit eri sijainneista otetuissa kuvissa näyttävät eriltä perspektiivin muutoksen takia. Tätä kutsutaan

stereoskooppiseksi parallaksiksi (Ikkala 2019). Kun objekti on kuvattu useista eri suunnista 2D-kuviksi, ja tiedetään asemat ja asennot, joista kuvat on otettu, voidaan siitä SfM-tekniikalla muodostaa kolmiulotteinen malli (Humboldt State University 2017). SfM-tekniikka (engl. *Structure from Motion*) muodostaa ilmakuvista pistepilviä hyödyntäen kuvien limityksiä ja stereoskooppista parallaksia tunnistuen päällekkäisistä kuvista eri kulmista esiintyviä samoja objekteja ja piirteitä (Lucieer et al. 2014, s.2; Humboldt State University 2017; Ikkala 2019). Näistä harvapistepilvistä voidaan muodostaa ortokuvia, niiden yhdistelmiä, eli ortomosaiikkeja, sekä erilaisia pintamalleja, kuten DSM (engl. *Digital Surface Model*) (Humboldt State University 2017). Ortokuvalla tarkoitetaan ilmakuvaa, jossa perspektiivivirhe on korjattu niin, että se vastaa perspektiiviltään karttaa, eli kaikki kuvan pisteet on kuvattu suoraan ylhäältä (Ikkala 2019). DSM on pintamalli, joka kuvastaa ilmakuvatun alueen pinnan muotoa (Ikkala 2019). DSM:ssä on mallinnettuna kaikki ilmakuvissa esiintyvät pinnat mm. kasvillisuus ja rakennuksen mukaan lukien (Ikkala 2019). Suodattamalla DSM-mallia voidaan siitä edelleen tuottaa DTM (engl. *Digital Terrain Model*) tai DEM (engl. *Digital Elevation Model*). DTM:llä tarkoitetaan pintamallia, joka kuvaa pelkästään maanpintaa. DTM:n tuottamisessa DSM:stä on tiettyjä rajoitteita, sillä mallista joudutaan suodattamaan pois kuvissa oleva kasvillisuus, jonka peittämä maanpinta ei ole välttämättä tallentunut riittävän hyvin kuviin, jolloin sen kuvaus DTM:ssä voi olla epätarkkaa (Ikkala 2019). DEM taas on rasteriverkko, joka kuvaa myös maanpintaa (Ikkala 2019). Joissain konteksteissa DEM ja DSM saattavat tarkoittaa samaa (Ikkala 2019). Yleinen SfM-algoritmia hyödyntävä pintamallien ja ortokuvien tuottamiseen käytettävä ohjelmisto on Venäläislähtöisen Agisoft LLC:n Photoscan (versiosta 1.5 eteenpäin Metashape) -ohjelmisto

UAS:n lennättäminen on ilmailua. Sitä koskee Ilmailulaki (864/2014) sekä Liikenteen turvallisuusvirasto Trafín määräys OPS M1-32 Kauko-ohjatun ilma-aluksen ja lennokin lennättäminen (Ikkala 2019, Trafi 2018). Lisäksi 1.1.2021 tulee voimaan Euroopan Unionin yhteinen EU-droneasetus, jolla UAV-laitteiden lentämistä harmonisoidaan koko Unionin alueella (Liikenne- ja viestintävirasto Traficom 2020a). Käytännössä lainsäädäntö rajoittaa esimerkiksi dronen eli lennokin kokoa ja missä sitä saa lennättää. Esimerkiksi lentoasemien, tietyillä teollisuusalueilla, suurten kaupunkien keskustoissa ja ihmisjoukkojen läheisyydessä lentämistä on rajoitettu. Lennokki ei myöskään saa olla 25 kg painavampi, eikä sillä saa lentää 150 m (EU-droneasetuksen myötä 120 m)

korkeammalla. Droneen täytyy aina lentäessä olla näköyhteys ja sillä ei saa aiheuttaa vaaraa tai häiriötä sivullisille. (Liikenne- ja viestintävirasto Traficom 2020b, 2020c)

UAS-kuvaukset alkavat lentosuunnittelulla. Kun tarkoituksena on kuvata soilla maanpintaa ja tehdä kuvista ortokuvia ja pintamalleja, suunnitellaan lentoreitti, joka tavallisessa tapauksessa on grid-mallinen, jossa UAV lentää siksakkimaisella kuviolla kuvattavaa aluetta niin, että kuvat limittyvät eli asettuvat osittain toisten kuvien päälle (engl. *frontal overlap & side overlap*) (Ikkala 2019). Joissakin tilanteissa voi olla tarpeellista käyttää ristikkäistä siksakkikuviota, jotta saadaan kaikki objektit kuvattua riittävän monesta suunnasta (Ikkala 2019). Ohjauslaitteistoihin usein on saatavilla ohjelmistoja, jotka automaattisesti suunnittelevat lentoreitin valitun alueen, limityksen ja lentokorkeuden perusteella, jonka jälkeen ne ilmoittavat lentoon tarvittavan ajan ja kuvien määrän. Jotkin ohjelmistot suunnittelevat lentoreitin myös kuvattavan kohteen ominaisuuksien perusteella: kuvataanko siis esimerkiksi rakennettua ympäristöä, metsää, tai, kuten tässä tapauksessa, eriasteisen kasvillisuuden peittämiä suoalueita, joissa suon pinnan monimutkainen mikrotopografia ja pintavedet aiheuttavat omat haasteensa.

Yleinen suositus limitykselle on 75 % lentosuunnan limitystä ja 60 % sivusuunnan limitystä, jolloin seuraava kuvassa on 75 % edellisestä kuvasta lentosuunnassa ja 60 % lentosuunnan viereisestä kuvasta (Ikkala 2019). Kun kuvataan tiheää kasvillisuutta, metsää, tasaista maata, pelloja ym. suosituksena on käyttää 85 % lentosuunnan ja 70 % sivusuunnan limitystä. Limityksen avulla jokainen kuvattava piste saadaan tallennettua useaan kuvaan. UAS-laitteisto tallentaa UAV:n sijainnin jokaisen kuvan ottohetkellä. Näiden tietojen pohjalta voidaan stereoskooppisen parallaxin avulla laskea korkeusmalli kuvatulle alueelle (Ikkala 2019). Rosnell & Honkavaara (2011, Gindraux et al. 2017 mukaan) huomasivat tutkimuksessaan suuremman limityksen parantavan pintamallin tarkkuutta merkittävästi.

UAS-kuvantamisessa nk. GSD-arvo (engl. *Ground Sampling Distance*) kertoo kuvien tarkkuudesta. GSD [cm/pikseli] on peräkkäisten pikselien keskikohtien etäisyys, eli käytännössä kuvaa pikselikokoa, joka määrittää millaista tarkkuutta lopputulos edustaa ja millaisia yksityiskohtia siitä on mahdollista havaita (Pix4D, 2020). GSD riippuu lentokorkeudesta  $H$  ja kameran ominaisuuksista. Lentokorkeus  $H$  voidaan laskea kaavasta (Pix4D 2020)

$$H = (imW * GSD * F_R) / (S_W * 100), \quad (3)$$

missä  $H$  on lentokorkeus [m],  
 $imW$  on kuvan leveys pikseleissä [pikseliä],  
 $GSD$  on haluttu tarkkuus eli vierekkäisten pikselien keskikohtien etäisyys [cm/pikseli],  
 $F_R$  on kameran todellinen polttoväli [mm],  
 $S_W$  on kameran kuvakennon todellinen leveys [mm].

Jos  $H$  tiedetään, kaavasta (3) voidaan laskea  $GSD$  kaavalla

$$GSD = \frac{H * S_W * 100}{imW * F_R}. \quad (4)$$

Periaatteessa kuvatessa halutaan mahdollisimman tarkkoja kuvia, jolloin  $GSD$ :n arvo on pieni.  $F_R$ ,  $imW$  ja  $S_W$  ovat UAV-laitteeseen liitetyn kameran ominaisuuksia, joten samalla laitteistolla kuvattaessa ainoastaan  $H$  ja  $GSD$  ovat muuttujia, joihin voidaan vaikuttaa kuvaustilanteessa. Mitä matalammalla UAV lentää kuvatessa (mitä pienempi  $H$ ), sitä pienempään  $GSD$ :n arvoon päästään eli sitä tarkempia kuvat ovat. Vastavuoroisesti mitä pienempää  $GSD$ :tä vaaditaan, sitä enemmän kuvia tietyltä alueelta joudutaan ottamaan koko alueen kuviin saamiseksi, ja siten tuloksena saadut kuvat vaativat suuremman tallennustilan ja suuremman jälkiprosessointikapasiteetin. Siten onkin järkevää säätää  $GSD$  sopivaksi sen mukaan, mitä kuvista halutaan tunnistaa. Jos halutaan tunnistaa soilta avovesipintoja tarkasti, tulisi  $GSD$ :n olla alle 10 cm, koska avovesipinnat voivat olla hyvinkin pienissä suon pinnan painaumuissa. Tästä syystä esimerkiksi satelliiteista otetut ilmakuvat eivät välttämättä sovellu avovesipintojen tunnistamiseen suuren  $GSD$ :n arvon takia. Ongelmallista on, voiko avovesipinnan esiintymän olettaa vastaavan suoveden pinnantasoa, vai onko se esimerkiksi vielä suodattumatonta sadevettä. Tämän vuoksi kuvaus olisi syytä tehdä pitemmän sateettoman kauden jälkeen, jolloin voidaan luotettavammin olettaa avovesipintojen vastaavan paikallisesti WT:tä. Esimerkiksi Lucieer et al. (2014) kuvasivat droneen liitetyllä digitaalisella Canon 550D järjestelmäkameralla mikrotopografisesti monimutkaista sammalpeitettä, ja pääsivät lentokorkeudella  $H = 50$  m  $GSD$ -tarkkuuteen  $GSD = 1$  cm. de Roos et al. (2018) kuvasivat tutkimuksessaan rahkasammalsoita Tasmaniassa, Australiassa, ja pääsivät ortokuvan resoluutioihin  $GSD = 2$  cm ja  $GSD = 1$  cm, sekä DSM:n resoluutioihin  $GSD = 3$  cm ja  $GSD = 2$  cm lentokorkeuksilla  $H = 40$  m ja  $H = 30$  m ja ristikkäisellä grid-mallisella lentosuunnitelmalla.

Passiivisella fotogrammetrialla voi olla hankalaa tuottaa tarkkoja pistepilviä esimerkiksi tilanteissa, joissa kuvattava pinta on monotonista tai pinnan tekstuuri on homogeenista (Lovitt et al. 2017, s.2). Näissä tilanteissa SfM-algoritmillä on vaikeuksia tunnistaa pinnasta solmupisteitä, siis objekteille ominaisia piirteitä, koska niitä esiintyy useissa muissakin objekteissa (Lovitt et al. 2017, s.2). Seisova vesi aiheuttaa myös hankaluuksia SfM-algoritmillemme pinnan homogeenisuuden takia (Lovitt et al. 2017, s.2). Edellisten lisäksi esimerkiksi linssin aiheuttama vääristymä pienillä polttovälin arvoilla tai lähes yhdensuuntaiset kuvaussuunnat voivat aiheuttaa tuotetuissa pintamalleissa systemaattista virhettä, jossa pinta muuttuu todellisuutta kuperammaksi, vääntyy tai kallistuu vaikka kaltevuutta ei todellisuudessa esiintyisi (James & Robson 2014; de Roos et al. 2018). Lisäksi otetuissa ilmakuvissa on geometrista virhettä kameran perspektiivin takia (Ikkala 2019). Kuvien heikko laatu ja lentokorkeus voivat myös heikentää pintamallien tarkkuutta (Gindraux et al. 2017). GCP:itä (engl. *Ground Control Point*) käyttämällä voidaan hillitä prosessoinnin aiheuttamaa systemaattista virhettä (de Roos et al. 2018; Gindraux et al. 2017).

Korkeusmallien tarkkuutta voidaan parantaa georeferoimalla kuvia GCP-pisteillä. Kuvissa GCP:nä voidaan käyttää mitä tahansa selvästi erottuvaa pistettä, jonka tarkat koordinaatit tiedetään (Ikkala 2019). Prosessointivaiheessa kuvasarjasta etsitään kaikki tiedetyt GCP:t ja ne sidotaan koordinaatteihinsa. Kuvauksen lentokorkeus määrittää millaisia GCP:t voivat olla: jos lennetään korkealla ja GSD on suuri, on pieniä objekteja hankala tunnistaa kuvista. Gindraux et al. (2017) tutkivat GCP:iden määrän ja jakauman vaikutusta pintamallien tarkkuuteen jäätikköalueita kuvattaessa, ja huomasivat, että pintamallin tarkkuus kasvaa asympotoottisesti kun määrää kasvatetaan tiettyyn tiheyteen saakka. He huomasivat myös, että DSM:n epätarkkuus kasvaa mentäessä kauemmas lähimmästä GCP:stä, tyypillisesti 0,09 m 100 m:n matkalla (Gindraux et al. 2017). de Roos et al. (2018) testasivat tutkimuksessaan kolmea eri GCP-asetelmaa viidellä eri suokohteella Australiassa, joista kahdella neljä GCP:tä riittivät tarkan DSM:n tuottamiseen, kun kolmella oli tarpeen käyttää kaikkia 16-20 GCP:tä. Ilman GCP:itä tehdyissä DSM:issä esiintyi myös keinotekoista kaltevuutta suolla. Matemaattisesti GCP:itä tulisi olla vähintään kolme, jotta jokainen koordinaatiston suunta voidaan sitoa (Ikkala 2019). Suositus kuitenkin on, että käytettäisiin viidestä kymmeneen GCP:tä kuvauksessa, ja jokaisen GCP:n tulisi näkyä vähintään kahdessa kuvassa (Ikkala 2019).

Lucieer et al. (2014) pääsivät tutkimuksessaan ortomosaiikin ja DEM-mallin keskiarvoiseen spatiaaliseen tarkkuuteen  $E = 0,016$  m, kun RMSE oli 0,042 m. Tarkkuutta



arvioitiin 30 GCP:n avulla ja tutkimusalue oli pinta-alaltaan noin 2 ha. RMSE (engl. *Root Mean Squared Error*) eli keskineliövirheen neliöjuuri on regressioanalyysissä käytettävä residuaalien keskihajonta, joka kuvaa mitatun aineiston hajontaa verrattuna ennustettuun aineistoon (Statistics How To 2020). Tapauksissamme ennustettu aineisto on kuvista tuotettu pintamalli ja mitattu aineisto on GCP-pisteiden avulla arvioitua virhettä. Lovitt et al. (2017) arvioivat tutkimuksessaan RGB-kuvista, LiDAR-aineistosta ja yhdistetystä RGB- ja LiDAR-aineistosta tuotettujen pintamallien tarkkuutta suoalueella Kanadassa. Tutkimuksessa todettiin kohteessaan RGB-kuvista tuotetun pintamallin olleen tarkempi kuin LiDAR-aineistosta tai yhdistetystä aineistosta tuotetun tiheämmän pistepilven ansiosta ja soiden monimutkaisen mikrotopografian takia. Tutkimuksessa myös huomattiin, että RMSE kasvoi, kun kuvattuun alueeseen sisällytettiin pinnaltaan monimutkaisia alueita, siis käytännössä tiheän puuston alueita. Pinnaltaan yksinkertaisemmilla alueilla, eli harvan puuston suolla ja avosuolla DEM onnistui RGB-kuvista tuottamaan pintamallin 14-23 cm absoluuttisen virheen tarkkuudella, kun RMSE oli 15-28 cm.

## 2.7 Interpolointi

Rahman et al. (2017) testasivat artikkelissaan ”*A New Method to Map Groundwater Table in Peatlands Using Unmanned Aerial Vehicles*” uutta tapaa, jossa UAS:llä otetuista kuvista skaalattaisiin WT:n pinnan malli koko suon alueelle. Rahman et al. (2017) olettavat tutkimuksessaan, että suolla esiintyvät pintavesitaskut edustavat WT:tä paikallisesti, ja tunnistamalla ne kuvista, voidaan interpoloida WT koko kuvatusuon alueelle. Tutkimuskohteena tutkimuksessa oli 61 hehtaarin boreaalinen puustoinen räme Albertassa, Kanadassa, jonka kasvusto oli pääasiassa puiden osalta Pohjois-Amerikkalainen mustakuusi (*Picea mariana*), pensas- ja kenttäkerroksessa kasvoi lännenpursua (*Rhododendron groenlandicum*), puolukkaa (*Vaccinium vitis-idaea*) ja karpaloa (*Oxycoccus microcarpus*). Pohjakerros koostui rahkasammalista (*Sphagnum spp.*). Suolla WT oli pääasiassa suon pinnan tuntumassa siten, että suolla oli mm. suuri lampi ja pienempiä pintavesiesiintymiä ympäri tutkimusalueen. Tutkimusaluetta halkoi myös tie, putki ja useita pienempiä erityispiirteitä, kuten ”seismisiä linjoja”, joita on käytetty öljyn etsintään ja maankuoren kartoitukseen.

Tutkimusalue kuvattiin kerran UAS-laitteella. Tutkimuksessa käytettiin 20-megapikselin optisella kameralla tuotettua ilmakuva-aineistoa. Kuvauksessa GSD oli  $GSD = 2 \text{ cm}$ , joka

saavutettiin käyttämällä lentokorkeutena  $H = 110$  m, lentosuunnan limityksenä 80 % ja sivusuunnan limityksenä 60 %. Kuvien georeferoinnissa käytettiin kymmentä systemaattisesti aseteltua GCP:tä. Lisäksi ortokuvan ja pintamallien tarkkuuden arviointiin käytettiin 20 satunnaisesti aseteltua GCP:tä. Ortokuvien ja pistepilvien tarkkuudeksi saatiin x- ja y-suunnissa  $RMSE < 1$  cm ja z-suunnassa  $RMSE = 21$  cm. Tutkimuskohteelle asennettiin myös 31 vesikaivoa, joista WT:n todellinen taso mitattiin. Mittauksia käytettiin mallin virheen määrittämiseen. Pistepilven pistetiheys oli  $191,81$  pistettä/cm<sup>2</sup>. Pistepilvestä muodostetun ortokuvan resoluutio oli  $GSD = 3$  cm. DSM luotiin niin, että resoluutioksi saatiin  $GSD = 3$  cm, jotta se vastaisi ortokuvan resoluutiota.

Kuva-aineiston keräämisen jälkeen työnkulku eteni niin, että kuvista luotiin pistepilvi Agisoft Photoscan -ohjelmiston avulla. Photoscan etsii kuvista solmupisteet, tunnistaa tallennetut kameran asennot ja sijainnit, ja sitoo pisteet pistepilveksi GCP:iden koordinaattien avulla. Pistepilvestä Photoscan muodostaa kuvatun alueen pinnan muotoja kuvastavan verkon. Rahman et al. (2017) tuottivat DSM:n käyttäen ArcMap -ohjelmiston *LAS to Raster tool* -työkalua. Rahman et al. (2017) validoivat SfM:llä tuotetut pintamallit 678 mitatulla maapisteellä, eivätkä havainneet pintamallissa vääristymää. Pintamallista tuotettiin DTM käyttäen LAStools, Cloud Compare ja ArcMap -ohjelmistoja niin, että taustakohina poistettiin ensin Cloud Comparen *Statistical-outlier removal tool* -työkalulla ja lopuksi jäljelle jäänyt kohina poistettiin käsi LAStools -ohjelmistolla, jonka jälkeen pistepilvestä tuotettiin DTM ArcMap -ohjelmistolla. Lisäksi tuotettiin lehvästön korkeusmalli CHM (engl. *Canopy Height Model*) vähentämällä DTM:n korkeudet DSM:n vastaavista.

Ortomosaiikista ja CHM:stä luokiteltiin avovesipisteet ENVI-ohjelmiston avulla ja käsin. Avoveden luokittelua arvioitiin 140:llä mallipisteellä, ja avoveden luokittelussa virhe oli 4 %. Tämän jälkeen valittiin jokaiselle 50 m<sup>2</sup> solulle yksi avovesipiste edustamaan WT:tä. Piste valittiin niin, että sen WT oli mediaani koko solun avovesipisteiden WT:stä. WT-pinnan interpolaatioon käytettiin tämän jälkeen *ordinary kriging* -interpolointia, jota käytetään yleisesti ympäristötieteissä ja hydrogeologiassa (Rahman et al. 2017). WT interpoloitiin koko kuvausalueelle. Rahman et al. (2017) pääsivät tutkimuksessaan interpolaatiolla WT:n tarkkuuteen  $RMSE = 22,0$  cm keskiarvoisen virheen ollessa  $E = -0,9$  cm, ja WTD:n tarkkuuksiin  $RMSE = 20,3$  cm keskiarvoisen virheen ollessa  $E = -7,0$  cm. Suurimmat virheet mallissa olivat alueilla, joilla oli tiheää kasvillisuutta ja

puustoa sekä korkeamman maanpinnan alueilla, jossa näkyvän valon fotogrammetrialla tuotettu DTM ei ollut riittävän tarkka. Virheet olivat pääasiassa pieniä avosuoalueella. Tutkimuksen malli nojasi myös oletukseen huokoisesta väliaineesta ja suon pinnan pieneen kaltevuuteen.

### 3 TUTKIMUS

Osana Hydrologia LIFE -projektia Vesi-, energia ja ympäristötekniikan tutkimusryhmä testaa UAS-mittausten soveltuvuutta ennallistamisen seurannassa (Oulun yliopisto 2017). Tätä varten tässä työssä analysoidaan kahden suokohteen pistemäistä vedenpinnan korkeuden (WH, engl. *water height*) mittausaineistoa kahdelta mittauskaudelta 2019 ja 2020, sekä sovelletaan UAS-kuvista tuotettua pintamallia vedenpinnan tason (WT, engl. *water table*) arviointiin. Ensimmäinen kohteista on 1970-luvulla kuivatettu ennallistettava avosuokohde ja toinen sen luonnontilainen vertailukohde. Ensimmäinen mittauskausi sijoittuu aikaan ennen ennallistettavan kohteen ennallistamista ja toinen mittauskausi edustaa ensimmäistä mittauskautta ennallistamisen jälkeen. WH:n mittausaineistot muutetaan vedenpinnan syvyyden (WTD, engl. *water table depth*) arvoiksi, ja niitä verrataan tilastollisin menetelmin niin, että nähdään miten ennallistamistoimet suolla ovat vaikuttaneet sen WTD:hen ja miten WTD ennallistettavalla kohteella vertautuu luonnontilaisen vastaavaan. Hypoteesi on, että WT on ennallistettavalla kohteella syvemmällä, kuin luonnontilaisella vastaavalla ennen ennallistamista, ja että ennallistamistoimet nostavat WT:tä ja vaikuttavat veden pinnantason vaihteluun (WTF, engl. *water table fluctuation*) hillitsevästi. Vertailussa käytetään WTD:n keskihajontaa, vaihteluväliä, keskiarvoa ja mediaania. Keskihajonnan ja vaihteluvälin ajatellaan indikoivan eroja veden pinnantason vaihtelussa WTF. Keskiarvo ja mediaani taas kuvaavat yleisesti WTD:n tilaa mittauspisteissä mittauskaudella. WTD-aineiston virhettä arvioidaan Metsähallituksen työntekijöiden tekemien maastomittausten avulla.

Molemmilla kohteilla suoritettiin UAS-ilmakuvaus näkyvän valon kameralla kerran molemmilla mittauskausilla. 20.8.2019 tehdystä kuvauksesta tuotetaan kolmiulotteiset harvapistepilvet, tiheäpistepilvet, ortomosaiikkikuvat ja pintamallit. Ennallistettavan suon DEM-mallista tuotetaan kaksiulotteinen pinnan profiili suolla olleiden mittauspisteiden välille läheisten avovesipintojen kautta, josta suodatetaan pois kasvillisuus, kuten leikkaukselle osuneet puut niin, että pintamalli vastaa mahdollisimman hyvin pohjakerroksen pinnanmuotoa. Leikkauksen ulottuvuudet ovat matka leikkauksen profiilitaiteviivaa pitkin ja korkeus.

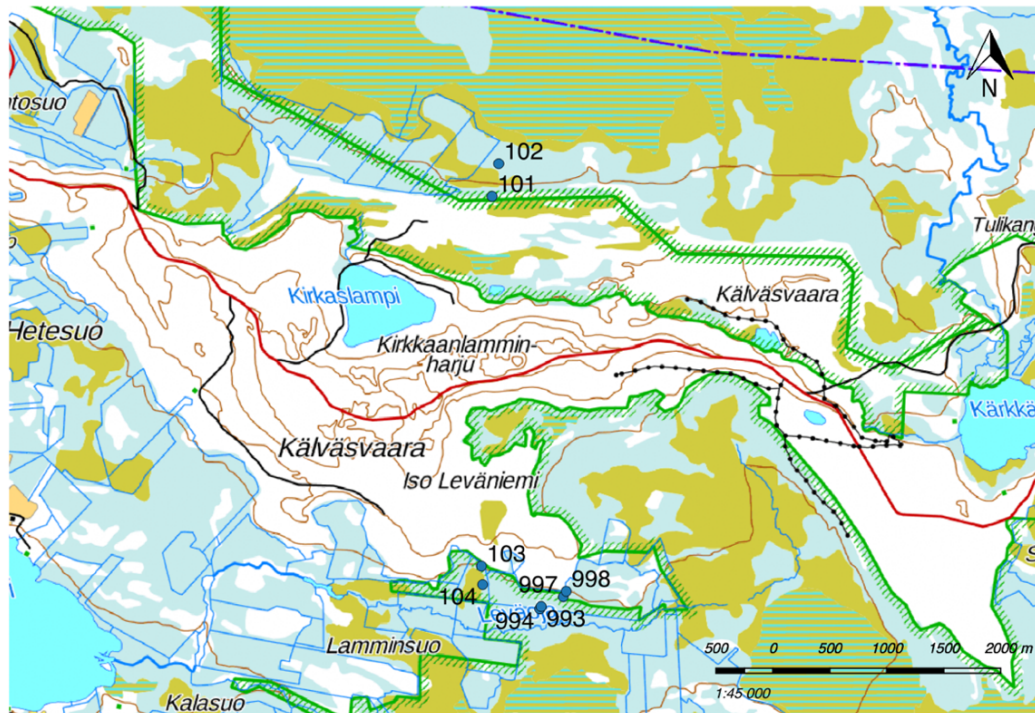
Tutkimuksessa oletetaan, että WT mukailee suon pinnan muotoja. Kaksiulotteiselle pinnan profiilille tuotetaan lineaarisesti interpoloimalla WT:n kaksiulotteinen profiili, niin, että se kulkee ortokuvista visuaalisesti erottuvien avovesipintojen kautta ja kohtaa

leikkauksen päissä eli mittauspisteillä mittausaineistosta saadut WTD:n arvot. Pintamallin profiilin jokaiselle pisteelle lasketaan jokaiselle mittauskauden päivälle WTD:n arvo irrottamalla WT:n profiili avovesipisteistä ja sitomalla se profiilin päissä WTD:n päivittäisen keskiarvon tasoon. Tämän jälkeen lasketaan jokaiselle profiilin pisteelle kuinka suuren osan ajasta WTD on ollut suon pinnan yläpuolella ja syvemmällä kuin 20 cm syvyydessä, sekä kuinka suuren osan ajasta näiden arvojen välissä. WTD:n aikaosuuksia ennen ja jälkeen ennallistamisen verrataan toisiinsa. Hypoteesi on, että ennallistamistoimet ovat nostaneet WT:n tasoa koko leikkauksella.

### 3.1 Kohteet

Hydrologia-LIFE -projektin 103:sta kohteesta tutkimukseen sisältyi Olvassuon Kirkaslammien lähetyvillä sijaitseva luonnontilainen suoalue sekä Iso Leväniemen lähistöllä sijaitseva ennallistuskohde (*Kuva 2*). Molemmat Olvassuon kohteet kuuluvat Valtioneuvoston päätöksellä vuonna 1998 SPA-statuksella suojeltuun Natura 2000 -alueeseen (Pohjois-Pohjanmaan ELY-keskus ja Kainuun ELY-keskus 2018). Olvassuo on Pudasjärven, Utajärven ja Puolangan kunnissa Iijoen ja Kiiminkijoen latvustoilla sijaitseva luonnonpuisto ja soidensuojelualue. Koko suojelualueen pinta-ala on 25 073 ha. Suomen ympäristökeskuksen (2013) mukaan alueella on runsaasti harvinaisia ja uhanalaisia lajeja, ja se on mm. edustava suurlinnuston pesimäalue Suomessa, ja suuri osa alueesta onkin Natura 2000 SAC- ja SPA- aluetta (Suomen ympäristökeskus 2013; Pohjois-Pohjanmaan ELY-keskus ja Kainuun ELY-keskus 2018). Olvassuo on laaja, edustava aapasuoalue, jossa metsäalueet ovat pieninä suosaarekkeina, ja joissa lahoppuuta on paljon tarjolla (Pohjois-Pohjanmaan ELY-keskus ja Kainuun ELY-keskus 2018). 73 % alueesta on soita tai rantakasvillisuutta, 20 % havupuumetsää (pääosin mäntyä, mutta myös kuusta), 4 % sisävesiä sekä 3 % sekametsää (Pohjois-Pohjanmaan ELY-keskus ja Kainuun ELY-keskus 2018). Aluetta halkovat muun muassa Nuorittajoki ja Piltuanjoki, sekä useita pienempiä puroja ja jokia. Siellä sijaitsee laajoja pohjavesivaikutteisia soita, joista osa on lettoja (Metsähallitus 2013; Pohjois-Pohjanmaan ELY-keskus ja Kainuun ELY-keskus 2018). Alueen lajistoon kuuluukin runsaasti harvinaisia ja uhanalaisia vanhojen metsien ja aapasoiden lajeja (Pohjois-Pohjanmaan ELY-keskus ja Kainuun ELY-keskus 2018), ja erämaisyyden sekä laajuutensa vuoksi alueella tavataan suurpetoja ja laajasti soiden ja erämaiden lintulajeja (Metsähallitus 2013). Olvassuosta noin 6000 ha laajuinen osa on luonnonpuistoa, jonka alueella liikkuminen merkittyjen reittien

ulkopuolella on sulan maan aikaan kielletty luonnonsuojelullisista syistä (Luontoon.fi 2020).

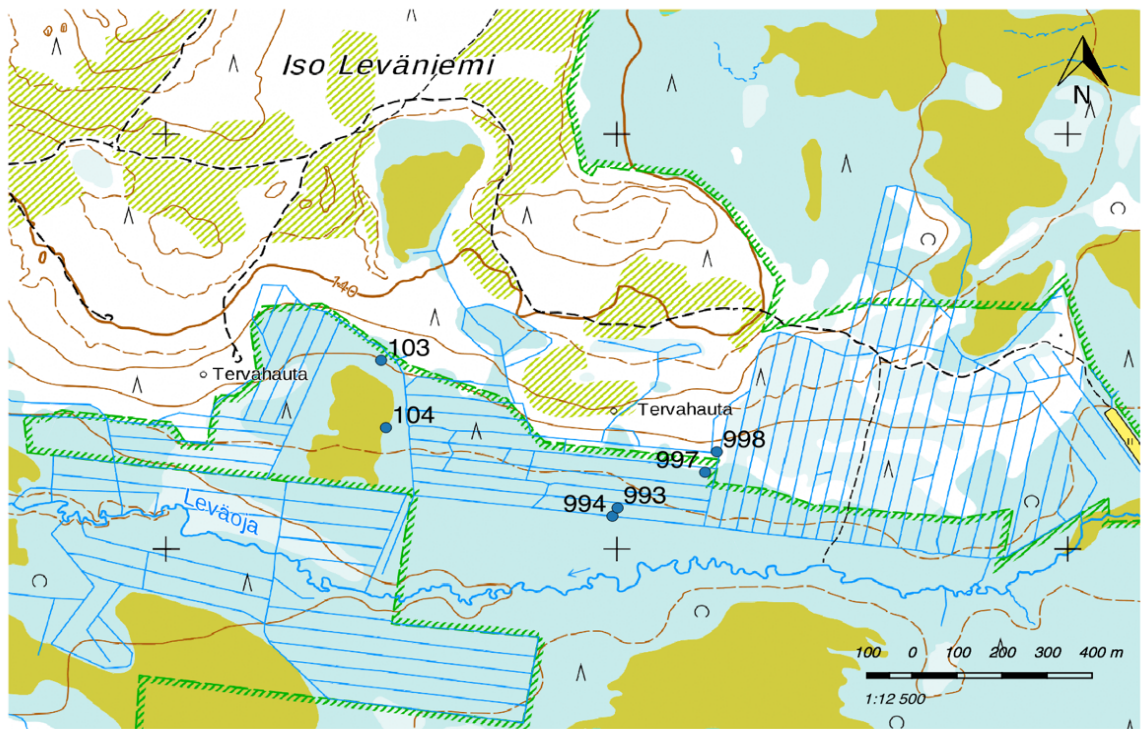


Kuva 2. Olvassuon tutkimuskohteiden vedenpinnan korkeuden WH automaattisten tiedonkeruulaitteiden eli loggerien kaivot kartalla. Kaivot 101 ja 102 sijaitsevat Kirkaslammen luonnontilaisella vertailukohteella, ja kaivot 103, 104, sekä 993-998 Iso Leväniemen ennallistuskohdeella. (Maanmittauslaitos 2020).

### Iso Leväniemen ennallistamiskohde

Olvassuon ensimmäinen kohde on loppukesällä ja syksyllä 2019 ennallistettu Iso Leväniemen suoalue (Kuva 3, Kuva 4 ja Kuva 5). Kuvissa näkyvä Iso Leväniemen ja Leväojan välinen suoalue on ojitettu arviolta vuonna 1975 (Rehell 2019), eli alueen vesitalouteen on aiheutettu häiriö yli 40 vuotta ennen ennallistamista. Iso Leväniemen suokohde sijaitsee Kälvasvaaran pohjavesimuodostuman eteläpuolella ja suo onkin vahvasti pohjavesivaikutteinen (Rehell 2020). Suo sijaitsee rinteessä, joten oletettavasti suoveden pinta mukaillee suon pinnan kaltevuutta. Tutkimukseen sisällytettiin kaksi avosuolla sijaitsevaa loggerikaivoa, joista 103 sijaitsee suon yläosassa lähellä suon pohjoisreunamaa ja 104 suon alaosassa (Kuva 3). Iso Leväniemen suoalueella sijaitsee neljä muuta loggeria (993, 994, 997 ja 998) (Kuva 2 ja Kuva 3), jotka eivät sisälly tutkimukseen.

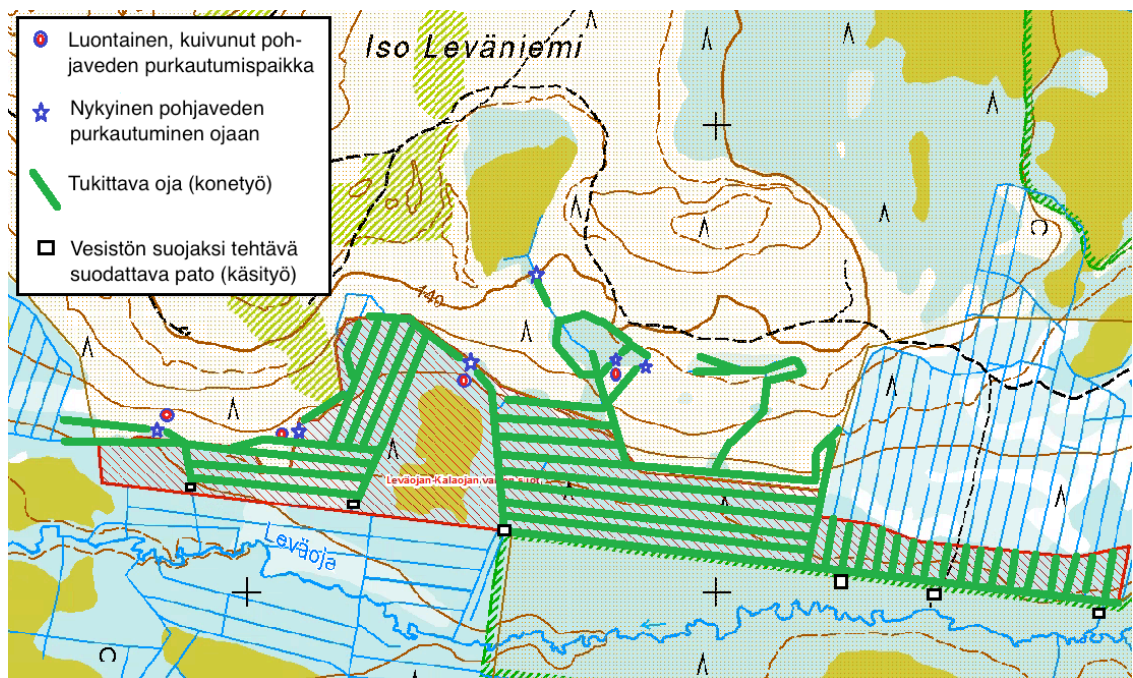




Kuva 3. Olvassuon Iso Leväniemen ennallistuskohde ja sinne sijoitetut vedenpinnan korkeuden automaattiset tiedonkeruulaitteet, eli loggerit. Tutkimukseen sisältyivät mittauspisteet 103 lähellä suon pohjoislaitaa ja 104 avosuoalueen keskivaiheilla. Pisteet 993-998 eivät sisällyneet tutkimukseen. (Maanmittauslaitos 2020).



Kuva 4. Olvassuon Iso Leväniemen suoalue luonnontilassa vuonna 1970 ja kuivatettuna ennen ennallistamista vuonna 2019 (ortokuva, kartta ja vanha kartta Maanmittauslaitos 2020)



Kuva 5. Oivassuon Iso Leväniemen ennallistuskohteen ennallistustoimenpiteet kartalla. Kuvan oikeudet omistaa Metsähallitus 2020, kartan oikeudet Maanmittauslaitos 2020.

Vanhaa ja uutta ilmakuvaa vertaamalla (*Kuva 4*) voidaan nähdä suurpiirteisesti kuinka Iso Leväniemen ja Leväojan välinen suoalue on muuttunut kuivatuksen myötä: ojitetut alueet molemmin puolin Leväojaa ovat muuttuneet huomattavasti puustoisemmiksi, mutta vihreällä rajattu avosuoalue ojitusten keskellä on pysynyt melko avoimena. Avosuoalueella vesi on virrannut vuonna 1970 otetusta ilmakuvasta päätellen pohjaveden purkautumispisteestä etelään kohti Leväojaa. Tummemmalla näkyvät osat avosuolla ovat oletettavasti suon märkäpintaa, kun vaaleammat osat ovat oletettavasti mätäs- tai välipintaa. Uudemmassa kuvasta päätellen märkäpinta on osittain säilynyt avosuolla ojituksesta huolimatta. Leväojan eteläpuolella säilyneestä avosuoalueesta lounaaseen on havaittavissa joitain jo kaivettuja ojalinjoja. Kälviäsvaaraan suoalueen pohjoispuolelle on vuosikymmenten saatossa tehty metsäautoteitä ja avohakkuita ja uudesta ilmakuvasta päätellen vaaran alue on pääasiassa metsätaloustaloudessa, kun vanhassa kuvassa vaara vaikuttaa lähes koskemattomalta, eikä kulku-uria ole, lukuun ottamatta vanhaan karttaan merkittyä koillis-lounaissuunnassa kulkevaa polkua. Vanhasta ilmakuvasta voidaan myös havaita lähes suoraan kohti avosuoaluetta pohjois-eteläsuunnassa kulkeva linja. Metsätaloustoimet Kälviäsvaarassa ovat vaikuttaneet sen ja ympäröivien alueiden vesitalouteen metsänpeitteen ja puuston muutoksen myötä, joka on vaikuttanut ainakin alueen transpiraatioon ja evaporaatioon ja siten suotautuvaan pohjaveteen. *Kuvan 4* uudemmassa, vuoden 2019 kartassa on merkittynä suojelualueen aiempi raja, jossa se



rajoittui ojituksen reunimmaisiiin ojiin, kun sitä on sittemmin laajennettu käsittämään ennallistettava alue (*Kuva 3*). Metsähallituksen ennallistamissuunnitelmassa (*Kuva 5*) on merkittynä paikat, joista Kälvasvaaran pohjavesi on ennen ojitusta purkautunut Iso Leväniemen suolle. Loggeri 101 on sijoitettu kuivuneen pohjaveden purkautumispaikan läheisyyteen. Ennen ennallistamista pohjavesi purkautui lähimpänä alkuperäisiä purkautumispaikkoja sijaitseviin kuivatusojiin (*Kuva 5*).

Iso Leväniemen suon yläosa edustaa suoluontotyyppiltään rimpistä lettonevaa, josta lettonevan indikaattorilajit ovat lähes kadonneet ja lajisto vastaa lähinnä karua kalvakkanevaa (Rehell 2020). Yläosan ajatellaankin olevan lettonevamuuttumaa (Rehell 2020). Lettonevat on koko maassa lueteltu uhanalaisuusluokkaan vaarantunut (VU), kun Etelä-Suomessa ne ovat äärimmäisen uhanalaisia (CR) ja Pohjois-Suomessa silmälläpidettäviä (NT) (Kaakinen et al. 2018b, s.382). Lettonevat ovat avoimia rimpitai välipintaisia soita, joiden vedet ovat lievästi happamia (Kaakinen et al. 2018b, s.382). Ne voidaan jakaa pohjakerroksen sammalpeitteen ja rimpitai ruoppapintojen esiintyvyyden mukaan alatyyppeihin, joita ovat rahkasammal-, aitosammal-, rahkasammalrimpi- ja ruopparimpilettonevat (Kaakinen et al. 2018b, s.382). Riippuen alatyypistä lettonevoilla voi esiintyä vaateliaitakin sammallajeja (Kaakinen et al. 2018b, s.382). Kenttäkerroskasvustona lettonevoilla esiintyy mm. tupasluikkaa (*Trichophorum cespitosum*), jouhisaraa (*Carex lasiocarpa*) ja siniheinää (*Molinia caerulea*), sekä vaateliaampia lajeja, kuten rimpivihvilää (*Juncus stygius*) ja pohjankarhunruohoa (*Tofieldia pusilla*). Lettonevojen mättäillä saattaa kasvaa myös harvakseltaan mäntyjä (*Pinus sylvestris*) (Kaakinen et al. 2018b, s.382).

Suon alaosan ajatellaan olevan saraista rimpinevamuuttumaa, josta rimpipinnan lajisto on lähes täysin hävinnyt, ja tilalle on kasvanut puutaimikkoa (Rehell 2020). Rimpinevat ovat tyypillisesti aapasoilla esiintyviä soiden märimpiä osia, joita esiintyy karuina ja ruohoisina (Kaakinen et al. 2018b, s.389). Suoluontotyyppin sisällä on paljon vaihtelua riippuen hydrologiasta, ja tutkimuskohteiden alaosat edustavat suursarojen (esim. pullosara eli *Carex rostrata* ja jouhisara eli *Carex lasiocarpa*) vallitsemia saraimpinevoja (Kaakinen et al. 2018b, s.389). Rimpinevojen uhanalaisuusluokka Suomen luontotyyppien uhanalaisuusarvioinnissa on koko maassa ja Pohjois-Suomessa säilyvä (LC), mutta eteläisessä Suomessa ne on luokiteltu erittäin uhanalaisiksi (EN) (Kaakinen et al. 2018b, s.389).

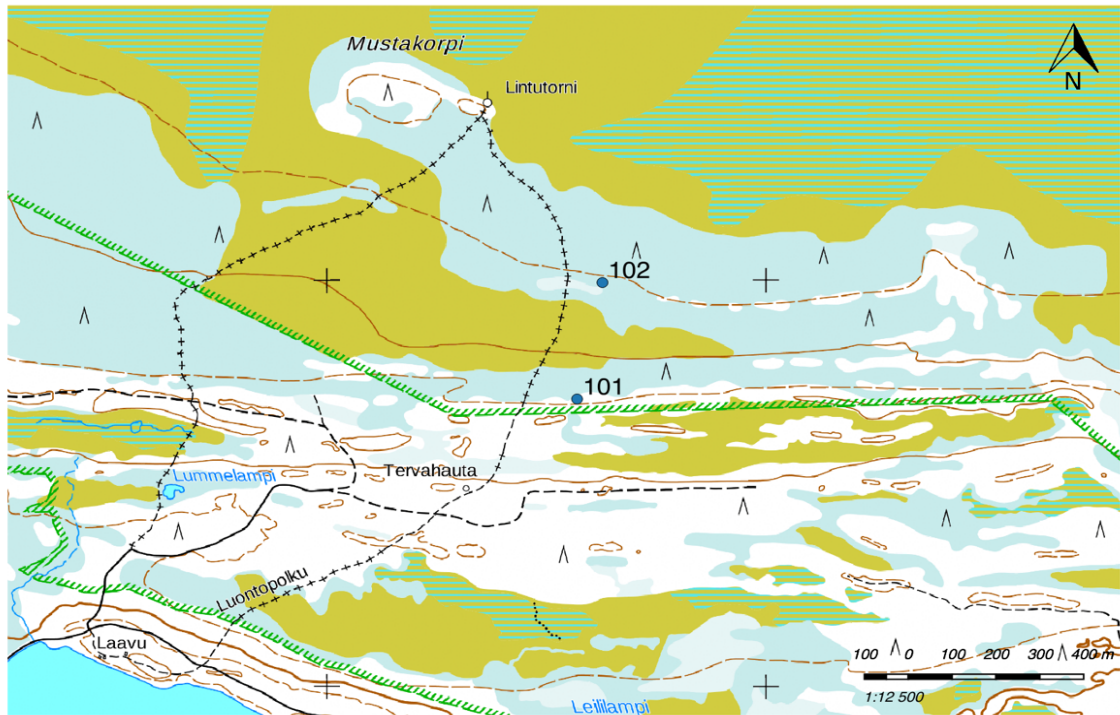
Iso Leväniemen ennallistamiskohteelle tehtiin ennallistamistoimina useita käsityöpatoja Leväojan vesistön suojelemiseksi heinä-elokuun 2019 aikana (*Kuva 5*). Lisäksi alueella tehtiin konetyönä ojen tukkimista 3.10.2019 alkaen. Metsähallituksen mukaan ennallistamistyöt valmistuivat noin 9.10.2019. Molempiin kohteisiin oltiin perustettu yhdeksän GCP:tä kesällä 2019. *Kuvassa 6* on nähtävissä loggerin 101 läheisyyteen perustettu GCP. GCP:t soilla olivat valkoiseksi maalattuja lautaristejä, jotka kiinnitettiin turpeen läpi mineraalimaahan asti lyötyyn paaluun. GCP:iden tarkat koordinaatit tallennettiin RTK-GPS -laitteella.



Kuva 6. Olvassuon Iso Leväniemen mittauspisteen 101 läheisyydessä sijaitseva ilmakuvien georeferointiin käytettävä lautaristi, eli GCP (engl. *ground control point*).

### **Kirkaslammen luonnontilainen vertailukohde**

Toinen Olvassuon kohteista on Kälväsvaaran pohjoispuolella sijaitseva Kirkaslammen luonnontilainen vertailukohde (*Kuva 7*). Myös Kirkaslammen suo sijaitsee rinteessä ja on vahvasti pohjavesivaikutteinen. Kirkaslammen kohteella on kaksi loggerikaivoa, joista 101 sijaitsee suon yläosassa ja 102 suon alaosassa (*Kuva 2 ja Kuva 7*). Rehelin (2020) mukaan Kirkaslammen pohjoispuolen loggerien paikat on valittu niin, että ne vastaisivat hydrologisesti ja geologisesti mahdollisimman hyvin Iso Leväniemen mittauspisteiden alkuperäistä tilannetta. Kirkaslammen suon yläosa edustaa lettonevaa ja indikaattorilajit ovatkin siellä hyvin havaittavissa. Suo alempi osa on Rehelin (2020) mukaan hyvin rehevää saraista rimpinevaa pohjavesivaikutuksen johdosta. Myöhemmin tutkimuksessa loggerikaivojen mittausaineistoja käsitellään koe-kontrollipareina, jossa ennallistuskohteen mittauspiste 103 on pari luonnontilaisen vertailukohteen mittauspisteen 101 kanssa ja koepiste 104 on pari luonnontilaisen kontrollipisteen 102 kanssa.



Kuva 7. Olvassuon Kirkaslammen luonnontilainen vertailukohde. Mittauspiste 101 sijaitsee suon yläosassa lähellä suon vaihtumisvyöhykettä, ja 102 suon alaosassa. (Maanmittauslaitos 2020)

### 3.2 Vedenpinnan tason seuranta


Molemmilla tutkimuskohteilla suon vedenpintaa monitoroitiin pistemäisesti ja jatkuvatoimisesti 30 minuutin välein kahdessa pisteessä. Monitorointiin käytettiin OmniLog TruTrack WT-HR 500 Water Height Data Logger -loggereita (Kuva 8). OmniLog TruTrack WT-HR -loggereissa on kapasitiiviset sensorit, jotka mittaavat vedenpinnan korkeutta (WH) ympäröivän väliaineen kapasitanssin muutoksen perusteella (TruTrack 2020; Balluf Inc. 2020). Loggeri tuottaa mittausaineistoa, joka ilmoittaa WT:n etäisyyden loggerin nollasensorista eli vedenpinnan korkeuden (WH) halutulla aikaintervallilla (Kuva 9). Loggerit mittaavat 50 cm mittausaluetta ja niillä voidaan mitata lisäksi sekä ilman että veden lämpötilaa. Loggerit vietiin loggerikaivoihin mittauskaudella 2019 2.7. ja haettiin pois 16.10., kun mittauskaudella 2020 ne vietiin 19.5. ja haettiin pois 13.10. (Taulukko 2). Käytetyt loggerikaivot ovat halkaisijaltaan 32 mm viemäriputkia, joiden yläpää on suljettu ja suon pinnan yläpuolella ja alapää avoin ja turpeessa. Kaivoissa kapillaarista nousua ei ilmene, joten taso, johon vedenpinta asettuu,



on pohjavedenpinnan taso WT. Lisäksi WT:tä seurattiin mittauspisteillä metsähallituksen työntekijöiden tekemien maastomittausten avulla.



Kuva 8. Omnilog TruTrack WT-HR 500 Data Logger Olvassuon Iso Leväniemen ennallistuskohteen suon yläosan mittauspisteestä 103.



Kuva 9. Havainnekuva loggerikaivosta, jossa on automaattinen vedenpinnan korkeuden tiedonkeruulaite eli loggeri.

### 3.3 Mittausaineiston käsittely

Metsähallitus toimitti Olvassuon kohteilta Omnilog TruTrack -loggerit maastokausilta 2019 ja 2020 ja datan purki loggereista Lauri Ikkala. WH mittauksissa on ilmoitettu millimetreinä loggerin sensorin yläpuolella puolen tunnin välein. Mittausaineisto muunnettiin vedenpinnan syvyyden WTD arvoiksi Microsoft Excel -sovelluksessa (versio 16.16.21), jossa WH:n mittaustulokset sidottiin suon pintaan loggerien asennusmittojen ja maastomittauksista saatujen Putki-mittojen avulla. Asennusmitalla tarkoitetaan loggerin nollasensorin etäisyyttä loggerikaivon korkista ja Putki-mitalla loggerikaivon yläpään etäisyyttä suon pinnasta (*Kuva 9*).

Loggerien asennusvaijerien pituuksia ei oltu dokumentoitu mittauskaudella 2019. Kuitenkin, loggerit asennetaan vuosittain samoille paikoille niin, että ne on kiinnitetty samalla tavoin loggeriputken korkkiin, ja tutkimuksessa oletettiin, että kesällä 2020 mitatut vaijerien pituudet (*Kuva 9*) pätevät myös mittauskaudelle 2019, joten niitä käytettiin aineiston WH-mittausten muuttamiseen WTD-aineistoksi. Tiedossa oli, että mittauskaudelle 2020 loggerien kiinnitysvaijereita lyhennettiin 14 cm, jotta vältettäisiin vedenpinnan nousu mittausalueen ulkopuolelle. Muunnos tehtiin kaikille loggerin mittauksille seuraavan kaavan avulla:

$$WTD(t) = \left(\frac{WH(t)}{10}\right) - Lg\ depth - Putki, \quad (3)$$

missä WTD(t) on vedenpinnan syvyys hetkellä t [cm],

WH on loggerin tuottama vedenpinnan korkeus [mm],

Lg depth on loggerin asennusvaijerin pituus loggerikaivon korkista loggerin nollasensoriin [cm], ja

Putki on loggerikaivon yläpään etäisyys suon pinnasta [cm].

Mittauskaudella 2019 loggerikaivoilla oli tehty yhdet maastomittaukset, joista Putki-mitat saatiin. Mittauskaudella 2020 maastomittaukset tehtiin kahdesti jokaisella loggerilla, joista Putki-mitaksi valikoitui se, jota käyttämällä käsimittausten virheen summa osoittautui pienimmäksi. Kompensatioon käytetyt mitat on lueteltu *Taulukossa 1*. Tuloksena saatiin vedenpinnan syvyyden WTD mittausarvoja eri ajanhetkinä. WTD:n negatiivisilla arvoilla veden pinta on suon pinnan alapuolella. Saatua aineistoa arvioitiin

kuvaajien avulla ja siitä poistettiin selviä poikkeamia, esimerkiksi loggerikaivojen asennuspäivien läheisyydestä, kun WT vasta asettui kaivossa todelliselle tasolleen.

Molemmissa Olvassuon kohteissa vedenpinta nousi syksyllä 2019 loggerien mittausalueen ulkopuolelle ennen loggerien hakua maastosta: ainoastaan Kirkaslammen suon yläosan loggerin 101 tuottamat mittaukset vaikuttivat valideilta koko mittauskauden ajan. Mittauspisteellä 102 Kirkaslammen luonnontilaisen suon alaosassa vedenpinta nousi mittausalueen yläpuolelle 1.9.2019, jonka jälkeen mittaukset pysyttelivät samassa arvossa  $WTD \approx 1,5$  cm (vastasi loggerin lukemaa  $WH = 655$  mm). Mittauspisteellä 103 Iso Leväniemen suon yläosassa vesi nousi mittausalueen ulkopuolelle myös osaksi syyskuuta 2019 ja syyskuun lopusta mittauskauden loppuun  $WTD$ :n arvolla  $WTD \approx -4,6$  cm ( $WH = 676$  mm). Mittauspisteellä 104 taas vesi nousi mittausalueen ulkopuolelle 6.10.2019  $WTD$ :n arvolla  $WTD \approx -10,0$  cm ( $WH = 617$  mm), ja pysytteli siellä mittauskauden loppuun saakka. Mittausalueen ulkopuolelle menneet mittaukset hylättiin eikä niitä otettu huomioon tilastollisten muuttujien laskennassa. Kaikki loggerien tuottamat mittauskauden 2020 mittaukset hyväksyttiin. Loggerien mittauskaudet ja hyväksytyjen tulosten aikavälit on ilmoitettu *Taulukossa 2*.

$WH$ :n muunnoksen virhettä arvioitiin maastomittauksista saadun  $WT$ -mitan avulla, joka voitiin muuntaa  $WTD$ :n arvoksi samoista mittauksista saadun Putki-mitan avulla (*Kuva 9* ja *Taulukko 1*). Loggerien  $WTD$ -arvoille maastomittauksista saatujen  $WTD$ :n arvojen avulla lasketut virheet olivat  $E \leq 10,4$  cm (*Taulukko 3*). Mittauspisteiden 102-104 aineistoille ei voitu määrittää virhettä mittauskaudelle 2019, sillä kun maastomittaus oltiin tehty, oli vesi jo noussut loggerin mittausalueen ulkopuolelle, eikä loggerin  $WTD$ :n arvoa ollut siksi mahdollista laskea tarkastusmittauksen ajanhetkelle.

$WTD$ -aineistot, joista oli poistettu alku- ja loppupään poikkeamat, muutettiin .csv-taulukoiksi, sarakkeissa päivämäärä, aika ja  $WTD$ . Tästä eteenpäin mittausaineistoa käsiteltiin R-ohjelmalla (versio 3.6.1), jota ohjattiin RStudio -ohjelmalla (versio 1.1.463). Tarkat ohjelmakoodit ovat liitteinä Liite 2–5. R-ohjelman *lubridate* -pakkausta käytettiin aineistojen päivämäärien muokkaamiseen ja pakkausta *dplyr* mittausaineiston muokkaamiseen. Ohjelman *ggplot2* -pakkausta taas käytettiin kuvaajien piirtämiseen pakkauksen *hrbrthemes* kanssa. Lisänä käytettiin *patchwork* -pakkausta kuvaajien yhdistämiseen. Esimerkiksi Menberu et al. (2016) käyttivät *unweighted moving average* -metodia (Marriot & Pope 1954) kohinan poistamiseen mittausaineistosta. Päädyttiin

kuitenkin muuttamaan mittaukset päivittäisiksi keskiarvoiksi hyväksytylle mittausajalle menetelmän yksinkertaistamiseksi. WTD-aineistoista ja WTD:n päivittäisistä keskiarvoista piirrettiin viivadiagrammit ja laatikko-janakuviot poikkeamien tunnistamiseksi.

Kaikkien loggerien kaikista WTD-arvoista laskettiin maksimi, minimi, mediaani, keskiarvo ja keskihajonta molemmille mittauskausille. Populaatiot aineistossa olivat useita tuhansia mittauksia. WTD-aineistojen jakaumaa testattiin piirtämällä niistä histogrammit, ja koska aineistot eivät seuranneet normaalijakaumaa, käytettiin Mann-Whitneyn U-testiä aineistojen mediaanien vertailuun. Mann-Whitneyn U-testi eli Wilcoxonin järjestyssummatesti on epäparametrinen tilastotieteellinen testi, joka järjestää havainnot suuruusjärjestykseen ja testaa poikkeavatko aineistojen mediaanit toisistaan (Ala-aho 2019). Testattavien aineistojen jakaumien ei tarvitse olla symmetrisiä, mutta niiden tulisi olla samanmuotoisia, jotta testi olisi yksiselitteinen (Ala-aho 2019). Alfa-riskin arvona käytettiin 0,05. Siis jos laskettava p-arvo on alle 0,05 nollahypoteesi hylätään, eli populaatioiden mediaanit eriävät toisistaan tilastollisesti merkittävällä tavalla (Ala-aho 2019). R-ohjelman käskyä *wilcox.test* käytettiin U-testin suorittamiseen. Kun odotuksena oli, että toinen aineistoista on mediaaniltaan suurempi, suoritettiin yksisuuntainen U-testi. WT:n vaihtelua WTF arvioitiin keskihajonnan ja vaihteluvälin avulla. Mittauskauden 2019 vaihteluvälit arvoitiin niin, että WT:n maksimin on ajateltu olevan WTD = 0 cm silloin, kun todellista maksimia ei voitu mittauspisteen tulvimisen takia määrittää.

Taulukko 1. Mitat mittauskausille 2019 ja 2020, joilla vedenpinnan korkeuden (WH) mittausaineisto mittauspisteistä 101-104 muutettiin vedenpinnan syvyyden (WTD) arvoiksi.

	Koeloggeri ja sen kontrollipari			
	Suon yläosa		Suon alaosa	
	103 koe	101 kontrolli	104 koe	102 kontrolli
[cm]				
2019 vaijeri	99,7	98,0	101,8	98,0
2019 putki	28,0	39,0	30,0	34,0
2020 vaijeri	85,7	84,0	87,8	84,0
2020 putki	21,0	34,0	24,0	27,0

Taulukko 2. Loggerien mittauskaudet ja hyväksytyt mittausvälit.

Mittauspiste	Mittausaika 2019	Hyväksytyt mittaukset 2019	Mittausaika 2020	Hyväksytyt mittaukset 2020
103 koe	2.7.-16.10.	2.7.-12.9, 17.- 29.9.	19.5.-13.10.	19.5.-13.10.
101 kontrolli	2.7.-16.10.	2.7.-16.10.	19.5.-13.10.	19.5.-13.10.
104 koe	2.7.-16.10.	2.7.-6.10.	19.5.-13.10.	19.5.-13.10.
102 kontrolli	2.7.-16.10.	2.7.-1.9.	19.5.-13.10.	19.5.-13.10.



Taulukko 3. Tuotettu vedenpinnan syvyyden WTD arvo (WTD logg.), Metsähallituksen maastomittauksista saatu WTD:n arvo (WTD käsi), ja näiden erotus (Virhe E). Päivälle 16.10.2019 tuotettu WTD logg. on päivän keskiarvo, kun muiden päivien WTD logg. ovat mittausajanhetken yksittäisiä arvoja. Positiivinen WTD on suon pinnan yläpuolella.

Pvm	[cm]	Suon yläosa		Suon alaosa	
		103 koe	101 kontrolli	104 koe	102 kontrolli
16.10.2019	WTD logg.	NA	-1,0	NA	NA
	WTD käsi	-14,0	-6,0	-11,0	-2,0
	Virhe E	NA	5,0	NA	NA
19.5.2020	WTD logg.	-7,3	-0,2	-11,8	-3,3
	WTD käsi	-7,0	1,0	-6,0	0,0
	Virhe E	0,3	1,2	5,8	3,3
13.10.2020	WTD log.	-1,6	4,0	-1,6	-6,0
	WTD käsi	-12,0	-2,0	-7,0	-3,7
	Virhe E	10,4	6,0	5,4	9,7

### 3.4 Sadehavainnot

Suomessa liikenne- ja viestintäministeriön hallintoalaan kuuluva Ilmatieteen laitos tuottaa muun muassa havainto- ja tutkimustietoa ja sää- ja ilmastopalveluita yleisen turvallisuuden, elinkeinoelämän ja kansalaisten tarpeisiin (Ilmatieteen laitos 2020b). Laitoksen noin 400 havaintoasemaa ympäri maan tuottavat mittausaineistoa esimerkiksi säästä ja sateista (Ilmatieteen laitos 2020c). Ilmatieteen laitos tarjoaa palvelun, josta voidaan ladata haluttu säähavaintoaineisto halutulta asemalta valitulle aikavälille (Ilmatieteen laitos 2020a). Sadehavainnot mitataan sää- ja sadeasemilla: sadehavaintoasemilla sademäärä mitataan kerran vuorokaudessa manuaalisesti, säähavaintoasemilla taas kymmenen minuutin välein automaattisesti (Ilmatieteen laitos 2020c, 2020d). Olvassuon Iso Leväniemi sijaitsee noin 14 km etäisyydellä lähimmästä Ilmatieteen laitoksen sadehavaintoasemasta Utajärven Särkijärvellä. Olvassuon

Kirkaslammen luonnontilainen kohde taas on noin 17 km etäisyydellä samasta havaintoasemasta, joka on havaintoasemista tutkimuskohdetta lähimpänä. Utajärven Särkijärven sadeaineisto ladattiin koko vuodelle 2019 ja 2020.

Ilmatieteen laitos tuottaa ja tarjoaa käyttöön myös koko maan kattavaa, hilaan interpoloitua säähavaintoainestoa, jonka avulla voidaan saada arvioita säästä sieltä, missä varsinaisia säähavaintoja ei ole tehty. Käytössä oli 10\*10 km<sup>2</sup> hilaan interpoloitua sääaineistoa, ja sitä käsiteltiin R-ohjelmalla (versio 3.6.1), jota ohjattiin RStudio -ohjelmalla (versio 1.1.463). Ensin hilan tietyn solun arvot poimittiin koko maan hila-aineistosta omalla R-koodilla mittauspisteen koordinaattien avulla, jonka jälkeen sitä käsiteltiin yhdessä WTD-aineiston kanssa. Hilaan interpoloitu päivittäinen sademäärä P ja ilman vuorokausikohtainen lämpötilan keskiarvo T piirrettiin samaan kuvaajaan kaikkien loggerien WTD-mittauksien kanssa koko mittauskauden ajalle. Samoin tehtiin Utajärven Särkijärven havaintoaseman P-havaintoaineistolle. Sadetapahtumat piirrettiin alkavaksi kaksi viikkoa ennen mittauskauden alkua.

Kaikille mittauspisteille laskettiin sadeaineistoista sademäärän summat molemmille mittauskausille ja ilman lämpötilan keskiarvo mittauskaudelle 2019. Sademäärän summa on laskettu niin, että mittauskausi on katsottu alkavaksi 14 päivää ennen hyväksytyn mittausvälin alkua (*Taulukko 2*), jotta nähtäisiin millaiset olosuhteet ovat aiheuttaneet mittauskauden alun tilanteen WT:ssä. Ilman lämpötilan keskiarvo taas on laskettu hyväksytylle mittausvälille.

### 3.5 Korkeusmalli

Itä-Suomen yliopisto suoritti UAS-kuvauksen Iso Leväniemen suolla 20.8.2019. UAS:nä toimi DJI Phantom 4 RTK, jonka kameran malli oli FC6310R. Kameran polttoväli oli 8,8 mm ja kuvien resoluutio oli 5742\*3648 pikseliä pikselikoolla 2,41 µm. Lentokorkeus kuvauksessa oli  $H = 123$  m.  $A = 0,314$  km<sup>2</sup> laajuisesta alueesta otettiin yhteensä 439 kuvaa, ja lentokorkeudella H kuvauksen GSD:ksi saatiin  $GSD = 2,79$  cm. Kuvauksen uudelleenprojisoinnin virhe oli 0,278 pikseliä.

Kuvat käsiteltiin Agisoft Metashape -ohjelmistolla (versio 1.6.3). Ensin kuvat tuotiin ohjelmistoon, jonka jälkeen ne tarkastettiin manuaalisesti. Kuvista poistettiin poikkeamat, huonolaatuiset ja huonosti tarkennetut kuvat. Tämän jälkeen ohjelmiston

automaatio etsi vierekkäisistä kuvista yhteiset piirteet, joista se muodosti harvapistepilven (engl. *sparse point cloud*). Kuvissa esiintyvät GCP-pisteet sidottiin käsin tunnettuihin GCP-koordinaatteihin, jonka jälkeen ohjelmisto tuotti automaattisesti kuvatusta alueesta tiheäpistepilven (engl. *dense point cloud*). Agisoftin *Classification* -algoritmilla tiheäpistepilvestä poistettiin DEM:in kasvillisuus, eli pääasiassa puut. Algoritmi ei tuottanut kuitenkaan täydellistä tulosta, sillä joitain ääriarvoja, jotka tunnistettiin ortokuvista puiksi jäi mittalinjalle ja nämä jouduttiin poistamaan mallista käsin. Tiheäpistepilvestä tuotettiin edelleen kaksi DEM-mallia: DTM ja DSM. DSM:n avulla ohjelmisto muodosti kuvista ortomosaiikin, ja lopuksi ohjelmasta vietiin raportti PDF-tiedostoon. Kuvatulla alueella oli yhdeksän GCP:tä, joista seitsemää käytettiin kontrollipisteinä kuvien sitomiseen koordinaatteihin. Kahta viimeistä GCP:tä käytettiin tarkastuspisteinä pintamallien suoriutumisen todentamiseksi. Kontrollipisteissä kokonaisvirhe oli  $RMSE = 1,8$  cm ja tarkastuspisteissä  $RMSE = 3,0$  cm. Suurin virhe oli z- eli korkeussuunnassa, joka oli kontrollipisteissä  $RMSE = 1,5$  cm ja tarkastuspisteissä  $RMSE = 2,0$  cm.

Lopuksi ohjelmistosta vietiin ulos ortomosaiikki, jonka resoluutio oli 5,0 cm. Ortomosaiikki avattiin ArcMap -ohjelmistossa (versio 10.6) jatkoprosessointia varten. Ortomosaiikkiin merkattiin mittauspisteiden 103 ja 104 sijainnit ja niiden väliltä tunnistettiin visuaalisesti kolme avovesipintaa. Mittauspisteiden välille piirrettiin mittalinja avovesipintojen kautta (*Kuva 10*). Tämän jälkeen käsittelyyn tuotiin DTM eli maanpinnan DEM-malli. *Resample* -työkalun avulla resoluutiota harvennettiin pikselikokoon 1 m laskennan keventämiseksi ja WT:n riittävän, muttei liian tiheän maanpinnan seuraamisen tuottamiseksi. Resoluutioon päädyttiin laskemalla profiileja useista resoluutioista välillä 0,05-5,00 m ja valitsemalla näistä silmämääräisellä arvioinnilla sopivin. *Resample* jakoi leikkauksen tasaväleihin ja tuotti askelpituuden 0,992 m. *Stack profile* -työkalun avulla profiilista luotiin taulukko, josta ilmeni valitun 1 m resoluution mukaisin välein tarkastelupisteiden vaakasuora etäisyys mittaviivan alkupäästä (loggeri 103) sekä pikselin z-koordinaatti (m mpy). Tämän jälkeen taulukko vietiin TXT -tiedostoon. Profiilin pituus on  $x = 169,78$  m, ja sen korkeus vaihtelee välillä  $z = 128,33 \dots 131,75$  m mpy. Profiilin keskipituuskaltevuus on siis noin 2 %. *Kuvasta 10* voidaan havaita mittauspisteeltä 103 avovesipisteisiin ulottuva jänne-rimpi-muodostuma, jonka eteläpäässä sidontaan käytetyt avovesipisteet sijaitsevat.



Kuva 10. Mittalinja Iso Leväniemen ennallistettavan suon mittauspisteiden 103,104 ja avovesipisteiden välillä, josta kaksiulotteinen suon pinnan profiili luotiin.

### 3.6 WT:n interpolaatio

Interpolaatio suoritettiin R-ohjelmalla (versio 3.6.1), jota ohjattiin RStudio -ohjelmalla (versio 1.1.463). RStudio -ohjelman *lubridate* -pakkausta käytettiin aineistojen päivämäärien muokkaamiseen ja pakkausta *dplyr* havaintoaineistojen muokkaamiseen. Kuvaajien piirtämiseen käytettiin *ggplot2* -pakkausta yhdessä *patchwork* -pakkauksen kanssa. Ensimmäisenä loggeri- ja avovesipisteiden välisen suon pinnan profiilin tiedot tuotiin TXT-taulukkona ohjelmaan. Oletuksena oli, että WT suolla seuraa turpeen pintaa valitulla resoluutiolla, vaikka pinnan mikrotopografia on monimutkaisempi. Leikkaukselle luotiin WT:n profiili niin, että suon pinnan profiilin alkupäää sidottiin loggerin mittauksista saatuun kuvauspäivän WTD:n keskiarvoon. Tämän jälkeen suon pinnan profiili interpoloitiin mittauspisteeltä 103 ensimmäiseen avovesipisteeseen lineaarisesti, ja jälleen kahteen seuraavaan avovesipisteeseen. Viimeisestä avovesipisteestä pintamalli interpoloitiin lineaarisesti leikkauksen loppupäähän eli loggerin 104 mittauksista saatuun kuvauspäivän WTD:n keskiarvoon.

WT:n interpolaatio laskettiin jokaiselle mittauskausien 2019 ja 2020 päiville niin, että sen alkupäää sidottiin ko. päivän mittauspisteen 103 WTD:n keskiarvoon ja loppupäää mittauspisteen 104 vastaavaan niin, että WT:n interpolaatio ei ollut laskennassa sidottu kuvauspäivän avovesipisteisiin ja se interpoloitiin lineaarisesti päätepisteidensä välillä. Tuloksena saatiin WT:n profiili mittauskausien jokaiselle päivälle. Jokaiselle leikkauksen pisteelle (1,0 m askeleet) laskettiin molemmille mittauskausille aikaprosenttiosuudet, jolloin WTD on ollut suon pinnan yläpuolella, suon pinnan ja WTD = -20 cm välissä, ja syvemmällä kuin WTD = -20 cm suon pinnan alapuolella. Tuotetusta profiilin WTD-aineistosta laskettiin vielä molemmille mittauskausille jokaiselle pisteelle maksimi, minimi, keskiarvo, mediaani ja keskihajonta, sekä koko tuotetulle profiilin WTD-aineistolle maksimi, minimi, keskiarvo ja mediaani. Tarkka R-koodi aineiston käsittelystä on liitteenä (Liite 1).

### 3.7 Tulokset

#### Vedenpinnan taso ja sen vaihtelu

Ennallistustoimet nostivat vedenpinnan tasoa (WT) ennallistuskohdeella. Tutkimuksen kaikkien mittausaineistojen tilastolliset tunnusluvut on esitetty mittauskaudelle 2019 ennen ennallistamista *Taulukossa 4* ja mittauskaudelle 2020 ennallistamisen jälkeen *Taulukossa 5*. Molemmilla mittauspisteillä 103 ja 104 Iso Leväniemen ennallistuskohdeella WT oli syvemmällä mittauskaudella 2019, kuin mittauskaudella 2020 (U-testi,  $p < 2,2E-16$ ). Ennallistuskohdeella WT oli syvemmällä kuin luonnontilaisella vertailukohdeella ennen ennallistamista: molemmilla mittauspisteillä Iso Leväniemessä WT oli syvemmällä kuin Kirkaslammen vertailukohdeella mittauskaudella 2019 vertailtaessa verrokkipareja, eli loggerien 101 ja 103 ja loggerien 102 ja 104 aineistoja toisiinsa (U-testi,  $p < 2,2E-16$ ). Ennallistamisen jälkeen mittauskaudella 2020 Iso Leväniemen suon yläosan mittauspisteen 103 WT oli korkeammalla kuin luonnontilaisella vertailukohdeella mittauspisteessä 101 (U-testi,  $p < 2,2E-16$ ). Iso Leväniemen suon alaosassa mittauspisteellä 104 WT jäi kuitenkin syvemmälle, kuin Kirkaslammen luonnontilaisen vertailukohteen alaosassa mittauspisteellä 102 (U-testi,  $p < 2,2E-16$ ). Tarkkaa p:n arvoa ei voitu U-testeille laskea, sen pienuuden ja laskentatehon rajoitusten takia. Kaikkien loggerien WTD:n viivadiagrammit on esitetty *Kuvassa 11* ja *Kuvassa 12*. Kuvaajista voidaan nähdä, että ennen ennallistamista

erityisesti kesän kuivana kautena heinäkuussa WT on tippunut syvälle ojitetulla Iso Leväniemen kohteella.


WT:n vaihtelu WTF pieneni ennallistuskohdeella ennallistamistoimien myötä ja oli lähellä luonnontilaisen vastaavaa ennallistamista seuraavana mittauskautena (*Taulukko 4* ja *Taulukko 5*). Iso Leväniemen mittauspisteellä 101 mittauskauden 2019 aineistossa ennen ennallistamista keskihajonta oli kolme kertaa suurempi verrattuna Kirkaslammen mittauspisteen 103 vastaavaan. Mittauspisteen 104 aineistossa suon alaosassa keskihajonta oli lähes kaksi kertaa suurempi verraten Kirkaslammen vastaavaan. Iso Leväniemen suolla mittausarvojen vaihtelu on siis ollut suurempaa, kuin Kirkaslammen suolla, mikä viittaa, että WTF on ollut suurempaa Iso Leväniemessä. Vaikka vaihteluväliä ei voitu laskea luotettavasti kaikille mittauspisteille ennallista edeltävälle kaudelle, oli se luonnontilaisella kohteella vähintään puolet pienempi verrattuna ennallistuskohteen vaihteluväliin. Molemmissa päissä suota vaihteluväli ja keskihajonta vastasivat lähes luonnontilaisen vastaavia ennallistamisen jälkeen.

Taulukko 4. Tutkimuskohteiden mittauskauden 2019 vedenpinnan syvyyden WTD:n tunnuslukuja, missä  $\mu$  on aritmeettinen keskiarvo, M on mediaani, Max on mittauskauden maksimiarvo, Min on mittauskauden minimiarvo ja  $\sigma$  on keskihajonta. Positiivinen WTD on suon pinnan yläpuolella.


Loggeri	$\mu$ (cm)	M(cm)	Max(cm)	Min (cm)	$\sigma$ (cm)
103 koe	-18,7	-13,6	NA	-42,8	12,8
101 kontrolli	-3,1	-2,5	3,3	-12,3	4,1
104 koe	-22,9	-19,0	NA	-44,0	9,4
102 kontrolli	-6,0	-5,3	NA	-16,7	5,5

Taulukko 5. Tutkimuskohteiden mittauskauden 2020 vedenpinnan syvyyden WTD:n tunnuslukuja, missä  $\mu$  on aritmeettinen keskiarvo, M on mediaani, Max on mittauskauden maksimiarvo, Min on mittauskauden minimiarvo ja  $\sigma$  on keskihajonta. Positiivinen WTD on suon pinnan yläpuolella.

Loggeri	$\mu$ (cm)	M(cm)	Max(cm)	Min (cm)	$\sigma$ (cm)
103 koe	4,5	5,0	9,4	-0,3	1,7
101 kontrolli	1,7	1,9	4,5	-2,6	1,5
104 koe	-5,7	-4,1	-0,5	-18,5	4,0
102 kontrolli	-1,9	-1,0	3,8	-21,3	4,9



Kuva 11. Koko tutkimuksen ajanjakson vedenpinnan syvyys WTD Kirkaslammen luonnontilaisen vertailukohteen mittauspisteessä 101 ja Iso Leväniemen ennallistuskohteen mittauspisteessä 103 soiden yläosassa. Positiivinen WTD on suon pinnan yläpuolella ja nollaviiva kuvastaa suon pintaa.



Kuva 12. Koko tutkimuksen ajanjakson vedenpinnan syvyys WTD Kirkaslammen luonnontilaisen vertailukohteen mittauspisteessä 102 ja Iso Leväniemen ennallistuskohteen mittauspisteessä 103 soiden alaosassa. Positiivinen WTD on suon pinnan yläpuolella ja nollaviiva kuvastaa suon pintaa.




## Ilmatieteen laitoksen sääaineisto


Hilaan interpoloitu ( $10 \times 10 \text{ km}^2$ ) sadeaineisto vastasi lähimmän havaintoaseman ainestoa paremmin WT:n vaihteluja, erityisesti Kirkaslammen luonnontilaisella vertailukohteella, joka sijaitsee kauempana havaintoasemasta, kuin Iso Leväniemen ennallistuskohde. WT:n muutokset vaikuttivat johtuneen pääasiassa evapotranspiraatiosta ja sadetapahtumista. Evapotranspiraatiolla tarkoitetaan yhdistettyä haihduntaa eli yhdistettyä evaporaatiota ja transpiraatiota. Esimerkkinä on esitetty viivadiagrammi Iso Leväniemen loggerin 103 WTD:n päivittäisestä keskiarvosta, hilaan interpoloiduista sadehavainnoista ja lämpötilahavainnoista solulle, jossa mittauspiste sijaitsee mittauskaudelle 2019 (*Kuva 13*). Lisäksi on esitetty mittauskauden 2020 loggerin 103 WTD:n päivittäinen keskiarvo sekä hilaan interpoloitu sadehavaintoaineisto (*Kuva 14*). *Taulukossa 6* esitetään hilaan interpoloidusta aineistosta lasketut sademäärän summat mittauskausille 2019 ja 2020 ja ilman lämpötilojen keskiarvot mittauskaudelle 2019. Mittauskauden 2019 sademäärän summa oli kaikilla pisteillä mittauskauden 2020 vastaavaa pienempi. Mittauskausi 2019 oli kuitenkin kaikilla pisteillä 2020 vuoden kautta lyhyempi, josta syystä sademäärien summat eivät ole suoraan verrattavissa. Kuvaajista (*Kuva 13* ja *Kuva 14*) voidaan kuitenkin havaita, että erityisesti heinäkuu 2019 oli vuoden 2020 heinäkuuta kuivempi tutkimuskohteilla: heinäkuussa 2019 sateita ei saatu juuri lainkaan, kun heinäkuussa 2020 saatiin useita yli 10 mm sadetapahtumia.

Taulukko 6. Mittauspisteiden sademäärän summa  $\Sigma P$  ja ilman lämpötilan keskiarvo  $\mu(T)$  mittauskausille 2019 ja 2020 hilaan interpoloidusta sääaineistosta.

Mittauspiste	2019 $\Sigma P$ (mm)	2019 $\mu(T)$ (°C)	2020 $\Sigma P$ (mm)
103 koe	152,6	12,0	412,3
101 kontrolli	183,6	10,5	408,8
104 koe	166,4	11,1	412,3
102 kontrolli	127,9	13,9	408,8



Kuva 13. Mittauskauden 2019 päiväkohtainen vedenpinnan syvyyden keskiarvo (WTD), hilaan interpoloidusta säädatasta saatu päiväkohtainen sademäärä (P) ja päiväkohtainen ilman lämpötila (T) mittauspisteessä 103 Iso Leväniemen ennallistuskohde. Positiivinen WTD on suon pinnan yläpuolella.



Kuva 14. Mittauskauden 2020 päiväkohtainen vedenpinnan syvyyden keskiarvo (WTD) ja hilaan interpoloidusta säädatasta saatu päiväkohtainen sademäärä (P) mittauspisteessä 103 Iso Leväniemen ennallistuskohde. Positiivinen WTD on suon pinnan yläpuolella.


### WTD:n aikaprocenttiosuudet mittauspisteissä

WT on ollut Kirkaslammen luonnontilaisella vertailukohteella (loggerit 101 ja 102) Menberun et al. (2016) määrittämällä turvetta muodostaville kasvilajeille avosoille optimaalisella syvyydellä (0...-20 cm) lähes koko mittauskauden 2019 (Taulukko 7). Osan mittauskaudesta suo on tulvinut eli WT on ollut suon pinnan yläpuolella. Kuivatetulla kohteella Iso Leväniemessä (loggerit 103 ja 104) WTD on ollut suuren osan mittauskaudesta 2019 syvemmällä kuin WTD = -20 cm, mittauspisteellä 104 lähes puolet koko mittauskaudesta. Ennallistamista seuraavana mittauskautena 2020 WTD on ollut säännönmukaisesti jokaisella pisteellä edeltävää kesää korkeammalla. Erityisesti soiden yläosassa mittauspisteillä 101 ja 103 suo on tulvinut lähes koko kesän. Kirkaslammen suon alaosassa suo on tulvinut noin kolmasosan mittauskaudesta. Iso Leväniemen suon alaosassa mittauspisteellä 104 WT vaihteli mittauskaudella suon pinnasta (WTD = 0 cm) 20 cm syvyyteen (WTD = -20 cm), eli pysyi koko mittauskauden Menberun et al. (2016) määrittämällä optimaalisella syvyydellä.

Taulukko 7. Tutkimuskohteiden mittauspisteiden vedenpinnan syvyyden WTD:n prosentuaalinen aikaosuus suon pinnan yläpuolella (>0cm), alle 20 cm suon pinnan alapuolella (Opt.), ja syvemmällä kuin 20 cm suon pinnan alapuolella (<-20cm).

Mittauspiste	Vedenpinnan taso % mittauskaudella 2019			Vedenpinnan taso % mittauskaudella 2020		
	> 0 cm	Opt.	< -20 cm	> 0 cm	Opt.	< -20 cm
103 koe	0,0	63,4	36,6	99,97	0,03	0,0
101 kontrolli	28,7	71,3	0,0	88,0	12,0	0,0
104 koe	0,0	55,4	44,6	0,0	100,0	0,0
102 kontrolli	14,9	85,1	0,0	34,5	64,0	1,5


### WT:n interpoloitu profiili ja sen aikaprosenttiosuudet




Kuva 15. Iso Leväniemen ennallistuskohteen mittauspisteiden 103 ja 104 välisen mittalinjan suon pinnan profiili, sidontapisteet ja interpoloitu WT kuvauspäivälle 20.8.2019.

Interpoloitu WT:n pinnan profiili seurasi avovesipisteiden välillä profiilin keskivaiheilla tarkasti suon pintaa (Kuva 15). Mittauspisteeltä 103 WT lähestyi avovesipisteitä niin, että z-suuntainen ero suon pinnan kanssa pieneni lineaarisesti interpolointitavasta johtuen. Viimeiseltä avovesipisteeltä mittauspisteelle 104 WT erkani lineaarisesti suon pinnasta z-suunnassa. Ennen jyrkempiä pinnanmuotoja WT on syvemmillä suon pinnan alapuolella, ja jyrkemmän pinnanmuodon jälkeen lähempänä suon pintaa. Kuvassa 16 ja Kuvassa 17 on esitetty viivadiagrammina Iso Leväniemen mittauspisteiden 103 ja 104 ja avovesipisteiden välinen suon pinnan profiili, WT:n interpolaatiot ja WTD:n aikaprosenttiosuudet koko ennallistamista edeltävälle mittauskaudelle 2019 ja ennallistamista seuraavalle mittauskaudelle 2020. Kuvaajissa on kuvattuna WT:n maksimi, minimi ja keskiarvo. Maksimi on päivä, jolloin askelpisteiden WTD:n summa oli suurin mittauskauden aikana. Minimi vastaavasti on päivä, jolloin pisteiden summa oli pienin. Keskiarvo on jokaisen pisteen mittauskauden keskiarvo viivadiagrammina. Kaikki profiilille lasketut tunnusluvut kasvoivat ennallistamisen jälkeiselle mittauskaudelle 2020 (Taulukko 8). WT nousi siis koko loggerien välisellä mittalinjan

profiililla (U-testi,  $p < 2.2E-16$ ). Interpoloidulle WT:lle laskettujen aikaprosenttiosuuskien mukaan suo tulvi lähes koko profiililla lähes koko mittauskauden 2020 (Kuva 17). Koko interpoloidun WT:n profiilin tunnusluvut ovat huomattavasti suurempia verrattuna pelkkien loggerien 103 ja 104 tuottamien aineistojen tunnuslukuihin (Taulukko 9). Ainoastaan aineistojen minimi ovat lähes samat, sillä mittauspisteiden 103 ja 104 WTD:n päivittäiset keskiarvot sisältyvät koko profiilin interpoloidun WT:n aineistoon.



Kuva 16. Mittauskauden 2019 Iso Leväniemen ennallistettavan tutkimuskohteen mittauspisteiden 103 ja 104 välinen suon pinnan profiili, vedenpinnan tason WT:n keskiarvo, minimi ja maksimi, sekä aikaprosenttiosuudet, jotka WTD on ollut syvemmällä kuin -20cm syvyydessä, suon pinnan (0 cm) ja WTD = -20 cm välissä, ja suon pinnan yläpuolella (WTD > 0 cm).



Kuva 17. Mittauskauden 2020 Olvassuon ennallistetun Iso Leväniemen tutkimuskohteen mittauspisteiden 103 ja 104 välisen leikkauksen suon pinta, WT:n keskiarvo, minimi ja maksimi, sekä aikaprosenttiosuudet, jotka  $\text{WTD} < -20\text{ cm}$ ,  $-20\text{ cm} < \text{WTD} < 0\text{ cm}$  ja  $\text{WTD} > 0\text{ cm}$  jokaisessa profiilin pisteessä. Positiivinen WTD on suon pinnan yläpuolella.

Taulukko 8. Koko Iso Leväniemen ennallistuskohteen mittauspisteiden 103 ja 104 välisen profiilin WTD:n tilastolliset tunnusluvut, missä  $\mu$  on aritmeettinen keskiarvo, M on mediaani, Max on mittauskauden maksimiarvo ja Min on mittauskauden minimiarvo. Ennallistamistoimet sijoittuivat osittain mittauskauden 2019 päälle ja mittauskausi 2020 oli ensimmäinen ennallistamisen jälkeen. WTD:n positiiviset arvot ovat suon pinnan yläpuolella.

Mittauskausi	$\mu$ (cm)	M (cm)	Max (cm)	Min (cm)
2019	-9,6	-5,9	10,9	-43,8
2020	12,3	12,1	22,8	-17,9

Taulukko 9. Iso Leväniemen ennallistuskohteen loggerien 103 ja 104 tuottamien aineistojen WTD:n tilastolliset tunnusluvut, missä  $\mu$  on aritmeettinen keskiarvo, M on mediaani, Max on mittauskauden maksimiarvo ja Min on mittauskauden minimiarvo. Ennallistamistoimet sijoittuivat osittain mittauskauden 2019 päälle ja mittauskausi 2020 oli ensimmäinen ennallistamisen jälkeen. WTD:n positiiviset arvot ovat suon pinnan yläpuolella.

Mittauskausi	$\mu$ (cm)	M (cm)	Max (cm)	Min (cm)
2019	-21,0	-17,8	NA	-44,0
2020	-0,6	0,3	9,4	-18,5

## 4 TULOSTEN TARKASTELU

### 4.1 Suon vedenpinnan vaihtelu

Kuten odotettua, ennallistamistoimet nostivat WT:tä ja hillitsivät WTF:ää ennallistuskohdeella. WT oli ennallistuskohdeella syvemmällä kuin luonnontilaisella vertailukohdeella ennen ennallistamista. Ennallistamistoimet nostivat WT:n suon yläosassa luonnontilaista verrokkia korkeammalle, kun suon alaosassa WT pysyi luonnontilaista verrokkia syvemmällä. On mahdollista, että ennallistamistoimet ovat vaikuttaneet liiaksi suon yläosaan, mutta eivät ole vaikuttaneet riittävästi suon alaosaan. Maastomittauksista arvioitu virhe on kuitenkin niin suuri verrattuna luonnontilaisen vertailukohteen ja ennallistuskohde WTD:n tunnuslukuihin, ettei ennallistamistoimien riittävyttä voida arvioida luotettavasti. Myös ennallistamistoimet mittauskauden 2019 aikana saattoivat vaikuttaa ennallistuskohde ennallistamista edeltävän kauden 2019 tilastollisiin tunnuslukuihin. Todellinen ennallistamisen hydrologisten vaikutusten toteaminen vaatii pidempää seurantajaksoa.

Vaikka kohteet sijaitsivat melko lähellä (14 km ja 17 km) lähintä Ilmatieteen laitoksen havaintoasemaa, vaikutti  $10 \times 10 \text{ km}^2$  hilaan interpoloitu sadeaineisto selittävän luotettavammin WTD:n muutoksia, erityisesti Kirkaslammen kohdeella, joka sijaitsi kohteista kauimpana. Luotettavuutta paransi hilaan interpoloidusta säädatasta saadut ilman lämpötila-arvot, joita Utajärven Särkijärven sadehavaintoasemalta ei ollut saatavissa Ilmatieteen laitoksen latauspalvelussa (2020a). Kuvaajista voitiin havaita, että sadetapahtumien jälkeen WT nousi mittauspisteissä, ja laski, kun sateita ei hetkeen ollut saatu, varsinkin silloin, kun ilman vuorokausikohtainen lämpötilan keskiarvo oli korkea. Mittauskaudella 2020 sadetapahtumien vaikutukset olivat hillitympiä, erityisesti kun WT oli mittauspisteessä suon pinnan yläpuolella. Kun halutaan tutkia sään vaikutusta WT:hen, ja tutkittava kohde sijaitsee 10 km lähempänä lähintä havaintoasemaa, on syytä tutkia havaintoaseman ja hilaan interpoloidun säädatan soveltuvuutta. Erityisesti, jos halutaan verrata eri kohteiden dataa, on syytä harkita, mitä aineistoa käytetään ja käytetäänkö samaa aineistoa kaikille kohteille, jotta aineistot ovat mahdollisimman vertailukelpoisia.

Käsimittauksista lasketut WTD:n virheet on taulukoitu *Taulukossa 3*. Virheet ovat pääasiassa alle 10 cm luokkaa. Virhe kuitenkin on kuitenkin merkittävä, kun halutaan



verrata mittauspisteiden aineistoja toisiinsa tai määrittää onko WTD ollut optimaalisella alueella turvetta tuottaville kasvilajeille. Menberu et al. (2017) määrittivät avosoille optimaaliseksi WTD:n vaihteluväliksi  $WTD = 0...-20$  cm ja puustoisille soille  $WTD = 0...-30$  cm. Koska optimaalinen vaihteluväli on pieni, voi 10 cm systemaattinen virhe loggerin mittauksissa johtaa virheelliseen päätelmään ennallistamisen onnistumisen arvioinnissa. Virheen merkitystä luonnontilaisen ja ennallistettavan kohteen vertailussa voitaisiin vähentää käyttämällä vertailuun useita luonnontilaisia kohteita, joka vähentäisi myös luonnollisen vaihtelun merkitystä vertailussa.

## 4.2 WT:n interpolaatio

Interpolaation perusteella WT nousi ennallistamistoimien myötä koko Iso Leväniemen mittalinjan profiililla (U-testi,  $p < 2,2E-16$ . Aapala et al. (2013, s. 76) määrittivät mätäs-, väli- ja rimpipintojen WTD:n vaihteluvälit. Määrittelyn mukaan mittauskaudella 2019 mittauspisteiden 103 ja 104 lähistö, eli noin 0-26 m ja 134-170 m profiilista olisi pääasiassa mätäs- tai välipintaa, sillä vesi ei näillä sektoreilla noussut suon pinnan yläpuolelle mittauskauden aikana, vaan pysytteli  $WTD = 0...-20$  cm välillä ollen kuitenkin merkittävän osan mittauskaudesta syvemmillä kuin 20 cm syvyydessä. Profiilin sektori 26 m ja 134 m välillä olisi määrittelyn mukaan väli- tai rimpipintaa, sillä WT nousi osaksi mittauskautta suon pinnan yläpuolelle. Erityisesti profiilin välillä 52...122 m WTD oli yli 40 % mittauskaudesta suon pinnan yläpuolella. Tämän välin voitaisiin arvioida olevan märkäpintaa.

Interpoloitu WT oli suon pinnan yläpuolella lähes koko leikkauksella lähes koko mittauskauden 2020 ajan. Ainoastaan profiilin pisteestä 128,33 m profiilin loppuun mittauspisteelle 104 (169,78 m) WTD on ollut osan mittauskaudesta suon pinnan alapuolella. Tästä voitaisiin tulkita, että ennallistamisen myötä WT on noussut niin paljon, että lähes koko profiilin voitaisiin ajatella olevan rimpipintaa. Ainoastaan loggerin 104 lähistö olisi välipintaa, sillä WT on osan mittauskaudesta suon pinnan alapuolella. Maastohavaintojen perusteella suo ei ole tulvinut yhtä mittavasti kuin tunnusluvut antavat olettaa mittauskaudella 2020.

Tutkimuksessa oletettiin, että WT suolla myötäilee suon pinnan muotoja. Interpoloitu WT seuraa suon pinnan muotoja hyvin, erityisesti, kun WT on suon pinnan alapuolella. Kuitenkaan, ei voitu varmistua vastaako interpolaatiotulos todellisuutta

validointiaineiston puutteen takia. Esimerkiksi profiilille sijoitettuvilla ylimääräisillä vedenkorkeushavainnoilla, jollaisia Rahman et al. (2017) olivat käyttäneet, olisi voitu arvioida interpolaation luotettavuutta ja virhettä. Interpoloitu WT seurasi suon pinnan muotoja myös ollessaan suon pinnan yläpuolella. Ei ole kuitenkaan realistista, että avovesi seuraisi suon pinnan muotoja. Interpolointitapaa tulisi kehittää siis erityisesti tilanteisiin, kun WT on suon pinnan yläpuolella. Yksi mahdollisuus on, että interpolointi tehtäisiin tutkimusosuudessa kuvaillulla tavalla, kun WT on suon pinnan alapuolella, mutta sen noustessa suon pinnan yläpuolelle, jatkaisi se matkaa horisontaalisesti, kunnes se kohtaa taas suon pinnan jänne-rimpi-järjestelmässä. Tässäkin menetelmässä ongelmia saattaisi tulla tutkimuskohteemme kaltaisilla kohteilla, joissa suon pinta viettää huomattavasti. Esimerkiksi, kuten tilanteessamme, kun interpolaatio aloitetaan leikkauksen korkeimmasta kohdasta ja WT on jo ko. pisteellä suon pinnan yläpuolella, saattaisi se jatkaa horisontaalisesti suon pinnan yläpuolella koko leikkauksen matkan, mikä ei vastaisi todellisuutta.

Tutkimuksessa pintamalli tuotettiin kuvista, jotka oli otettu ennen suon ennallistamista. Ennallistamisen myötä suon pinta nousee veden kelluttavan vaikutuksen, turpeen turpoamisen ja palautumisen johdosta. Menetelmää kehitettäessä voitaisiin tuottaa useita saman alueen pintamalleja useista kuvauksista, joista suon pinnan palautumisen vaikutusta sen topografiaan, interpolaatioon ja sen luotettavuuteen voidaan arvioida. Menetelmässämme pintamalli harvennettiin 1 m pikselikokoon, josta WT:n interpolaatio johdettiin, ja 1 m pikselikoon pintamallista tuotettua profiilia käytettiin myös kuvaamaan suon pintaa. Todellisuudessa suon pinnan mikrotopografia on paljon monimutkaisempaa, joten interpoloinnissa ja tunnuslukujen laskemisessa voitaisiin käyttää tarkemman pikselikoon profiilia kuvaamaan suon pintaa. Näin saataisiin todenmukaisempi kuva WT:n käyttäytymisestä. Pikselikoko (1 m) valittiin silmämääräisen arvioinnin perusteella, ja menetelmäkehityksessä voitaisiinkin validointiaineiston avulla arvioida, millainen pintamallin resoluution harvennus vastaisi WT:n pintaa parhaiten. Tutkimuksessamme ongelmaksi osoittautui myös kasvillisuuden suodattaminen pois pintamallista, ja osa kasvillisuudesta jouduttiin poistamaan käsin. Menetelmän kehityksessä on syytä löytää sujuvampi keino myös suodattamiseen.

Tutkimuksessa käytettiin kahta pistemäistä automaattista WT:n tiedonkeruulaitetta, joiden avulla spatiaalisesti kaksiulotteinen profiili WT:lle tuotettiin. Kolmantena ulottuvuutena toimi mittauskauden aika, kun WT johdettiin jokaiselle mittauskauden

päivälle. Jos käytössä olisi vähintään kolme pistemäistä WT:n aineistoa, olisi WT mahdollista interpoloida spatiaalisesti kolmiulotteisesti. Jos onnistutaan tuottamaan menetelmä, jolla WT voidaan luotettavasti interpoloida loggerien välille pintamallia hyväksikäyttäen, voidaan tulevaisuudessa jopa ekstrapoloida WT koko suoalueelle sitoen se WT:n vaihteluun esimerkiksi yhden loggerin havainnoilla. WT:n pistemäisen havaintoaineiston ja UAS-kuvauksista tuotetun pintamallin avulla voitaisiin siis mahdollisesti tuottaa neliulotteinen ekstrapolointi suon WT:stä.

### 4.3 Virhelähteet ja epävarmuudet mittauksissa

WTD-aineiston tilastollisia muuttujia vertailtiin koko niiden hyväksytyille mittausjaksoille. WTD muuttuu mittauskauden aikana ja vesi on tavallisesti korkeimmillaan kevään tulvien aikaan ja syvimmillään kesän kuivimpana kautena heinäkuussa, josta se syksyllä taas nousee pienemmän evapotranspiraation ja suurempien sademäärien myötä. Mittauskaudella 2019 mittausjaksot olivat eri mittaisia; kaikkien loggerien mittauskausiin sisältyi heinä- ja elokuu, mutta vain osan mittauskausi jatkui syyskuun alun jälkeen. Menberun (2016) soveltaman tekniikan mukaan WTD:n tulisi avoimilla soilla pysytellä optimaalisella alueella  $0 \text{ cm} > \text{WTD} > -20 \text{ cm}$ , joten tilastollisia muuttujia vertailtiin niin, että ne laskettiin jokaiselle mittauspisteelle koko niiden hyväksytyyn mittausjakson ajalle. WTD:n kausittaisen vaihtelun takia voidaan kuitenkin pohtia, olisiko järkevämpää vertailla muuttujia, kun ne on laskettu yhteneväisille mittausjaksoille. Myöskään tutkimuksessa tuotetun leikkauksen ja sille interpoloidun WT:n, ja WT:lle laskettujen tilastollisten muuttujien vertailu ei välttämättä ole validia mittauskausien eriävien pituuksien takia.

Loggerien tuottaman aineiston virheen arviointiin käytettiin pääasiassa Metsähallituksen työntekijöiden tekemiä tarkastusmittauksia. Tarkastusmittauksissa työntekijä mittaa loggerikaivon etäisyyden suon pinnasta (Putki) ja vedenpinnan etäisyyden loggeriputken päästä (WT). Vedenpinta mittauspisteillä on pääasiassa suon pinnan alapuolella ja mittaus tehdään puhallusputkella, jolla tarkka mittaaminen voi olla vaikeaa. Myös putken mitta, eli loggerikaivon pään etäisyys suon pinnasta voi olla paikoin vaikea mitata suon pinnan mikrotopografian takia: loggerikaivo saattaa sijaita suon mättään kyljessä tai muussa muodostumassa, jolloin suon pinnan taso voi olla loggerikaivon eri puolilla useita senttejä eri tasossa. Suon pinnan taso voi olla häilyvä myös kasvillisuuden takia: mitataanko putkimitta turpeen pintaan vai esimerkiksi sammaleen latvojen tasalle? Ei ole välttämättä

selvää mistä turve alkaa ja mihin kasvillisuus loppuu. Mittaustavoissa ja -tarkkuudessa on vaihtelua työntekijöiden välillä. Mittauksen merkityn ajankohdan tarkkuus saattoi vaihdella mittauksen tekijästä riippuen. Pääasiassa suokohteiden mittaukset tekivät samat henkilöt saman mittauskauden aikana, mikä yhtenäistää mittauskäytäntöjä, mutta saattaa johtaa systemaattiseen virheeseen mittauksissa, ja siten loggerien tuottamissa WTD:n aineistoissa.

Kuten aiemmin todettua, biodiversiteetti soilla on herkkä veden pinnantason vaihtelulle. Erilaiset WTD:n arvot ja vaihteluvälit suosivat erilaisia suokasveja, ja soiden erilaisissa mikrotopografisissa muodostumissa vallitsevat eri kasvilajit kosteudesta ja WTF:n suuruudesta riippuen. Suomessa kuivatettujen soiden ojitukset ovat usein vuosikymmeniä vanhoja, ja kun WT:n lasku johtaa turpeen kasaan painumiseen ja sen hajoamiseen, vanhoilla kuivatetuilla suoalueilla suon pinta on saattanut ajan saatossa painua huomattavasti. WT:n palauttaminen ennallistamalla ojitusta edeltäneelle tasolle saattaa tarkoittaa sen nostamista niin, että WT:n suhde suon pinnantasoon on eri, kuin ojitusta edeltäneelle suoluontotyyppille on ominaista. Ennallistetun suon WT saattaa olla siis ojitusta edeltävällä tasolla, mutta WTD ei vastaa esimerkiksi luonnontilaisen vertailukohteen vastaavaa. Tämä saattaa näyttäytyä yliennallistamisena suolla ja analyysissä, kun tutkittava muuttuja on WTD.

WTD:n muutosta arvioitiin koko pintamallista tuotetulle profiilille. Profiili tuotettiin 20.8.2019 otetuista ilmakuvista, kun pääasialliset ennallistamistoimet sijoittuivat myöhemmälle syksylle 2019. Ennallistamistoimet nostivat WT:tä suolla ja ovat luultavasti veden kelluttavan vaikutuksen johdosta nostaneet suon pintaa. Tutkimuksessa mittauskauden 2020 WTD määritettiin samalle suon pinnan profiilille, kuin mittauskauden 2019 WTD. Ennallistamisen myötä suon pinnan profiili on kuitenkin voinut muuttua niin paljon, että malli ei vastaa todellista pintaa mittauskaudella 2020. Tämä osaltaan heikentää interpolaation luotettavuutta mittauskaudelle 2020.

#### **4.4 Johtopäätökset ja suositukset**

Ennallistamistoimet olivat nostaneet WT:tä ennallistuskohdeella ja WTF oli tutkimuksen perusteella hillitympi ennallistamista seuraavana mittauskautena. WTD:n arviointiin mittauskaudella käytettiin WTD:n päiväkohtaisia keskiarvoja ja vertailut tehtiin käyttäen Mann-Whitneyn U-testiä. WTF:n arviointiin käytettiin WTD:n vaihteluväliä ja

keskihajontaa. WTD poikkesi kohteilla luonnontilaisesta molempina mittauskausina. Todellinen ennallistamisen onnistumisen seuranta vaatii pidempää seurantaa ja useampia mittausjaksoja. Myös ennallistamista edeltävän tilanteen tallentaminen pidemmältä ajalta olisi hyödyllistä ennallistamistoimien vaikutuksien arvioinnissa. Todellinen ennallistamisen onnistumisen toteaminen vaatii myös onnistumisen arviointia useampien muuttujien suhteen. Pelkkä WTD:n mediaanien vertailu eri mittauskausien välillä ei riitä, vaan on tärkeää tarkastella muutoksia muista näkökulmista, esimerkiksi vertailemalla hydrograafien kulmakertoimia, kuten Menberu et al. (2016) tutkimuksessa tehtiin. Lisäksi on tärkeää tutkia ennallistamisen onnistumista esimerkiksi biodiversiteetin ja ekosysteemin resilienssin kannalta.

WTD:n määrittäminen tutkimuksen mittauspisteille loggerien arvoista ei ollut yksiselitteistä. Tästä syystä olisi syytä huomioida ennallistamisen seurannassa, että maastomittaukset tehdään riittävän tarkasti ja riittävän usein mittauskauden aikana. Maastomittausten avulla voidaan varmistaa loggerien mittausten oikeellisuus, siis ettei WTD:n määrittämisessä WH:n mittausaineistosta ole systemaattista virhettä. Seurannassa käytettävien loggerien tulisi olla sellaisia ja asennettu niin, että koko mittauskauden WTD:n vaihtelu saadaan tallennettua. Tutkimuksessa arvioitiin todellisen WTD:n tarkimmaksi määritystavaksi kompensoinnin, jossa käytettiin loggerien asennusmittoja, jolloin maastomittauksia käytetään virheen arviointiin. Asennusmittoja ei kuitenkaan ollut saatavilla Metsähallituksen tietokannassa, ja siksi kompensoinnin todenmukaisuutta oli hankala varmentaa. Käytettyjen loggerien merkkejä ja malleja ei myöskään oltu tallennettu. Erilaisilla loggereilla lämpötila- ja ilmanpainekompensaatio saattavat toimia eri tavalla, joten mallit ja merkit olisi syytä dokumentoida hyvin, jotta voidaan varmistua loggerin tuottaman havaintoaineiston luotettavuudesta. Yleisesti voidaan sanoa, että loggerien asennus ja poishaku tulisi tehdä niin, että loggerien mallit, asennusmitat ja erityispiirteet dokumentoitaisiin hyvin. Työskentelyn objektiivisuutta voitaisiin parantaa esimerkiksi valokuvaamalla tilanne loggerilla maastomittausten, asennuksen ja poishaun yhteydessä.

Tutkimuksessa käytettyjen Omnilog TruTrack -loggerien ongelma oli lyhyt, vain 500 mm kattava mittausalue ja asennus liian syvälle. Mittausalue loggerissa lienee riittävä useimmille suokohteille, mutta tutkimuksen kohteella ennallistamistoimet tai syyssateet nostivat WT:tä niin paljon, että mittausalue ei riittänyt. Jos siis halutaan tallentaa ennallistamistoimien aiheuttama WT:n nousu, tulisi loggerit asentaa niin, että ne kattavat

koko WT:n vaihtelun pisteessä. Tätä voi asennusvaiheessa olla hankala arvioida, sillä WTF on suo- ja pistekohtaista. Luotettavampaa on käyttää WT:n tallentamisessa vesiloggereita, joiden mittausalue on tutkimuksessa käytettyjä suurempi, erityisesti kun kyseessä on vielä ennallistamaton kohde, joilla WTF on pääasiassa luonnontilaista ja ennallistettua kohdetta suurempaa. Metsähallitus käyttää yleisesti Solinst Levelogger - tiedonkeruulaitteita, joiden tallentama WH:n vaihteluväli ei ole niin rajoitettu, kunhan loggeri on asennettu niin syvälle, että se on veden peitossa koko mittauskauden.

Ruiz-Jaen & Aide (2005) suosittelevat artikkelissaan ennallistamisen onnistumisen arvioinnissa käytettäväksi vähintään kahta luonnontilaista vertailukohdetta, jotta luonnollinen vaihtelu eri kohteiden välillä minimoidaan. Tutkimukssamme käytettiin vain yhtä luonnontilaista vertailukohdetta. Järkevää olisi käyttää useampaa mahdollisimman samankaltaista vertailukohdetta. Myös loggerikaivojen paikkojen valinnassa on tärkeää etsiä luonnontilaiselta ja ennallistettavalta kohteelta mahdollisimman samankaltaiset pisteet, sillä soiden mikrotopografia, ja siten WTD voi muuttua paljonkin pienellä alueella. Luonnollista vaihtelua voitaisiin poissulkea esimerkiksi sijoittamalla useita vesiloggereita pienelle alueelle tai useammille samankaltaisille alueille luonnontilaisella vertailukohteella. Toisaalta, jos kohteen ojitusta edeltävästä tilasta ei ole riittävää tietoa, voi vertailu luonnontilaiseen kohteeseen olla lähinnä suuntaa-antavaa, riippuen siitä, mitkä ennallistamisen tavoitteet ovat.

UAS-kuvaus tarjoaa todellisia mahdollisuuksia ennallistamisen seurantaan. Jo pelkkä ennallistettavien soiden ja ennallistustoimien UAS-kuvaaminen dokumentoimisen tukena parantaa ennallistamisen objektiivisuutta. Tutkimuksessa tehty WT:n interpolointikokeilu vaikutti lupaavalta, vaikka sen suoriutumista ei voitu arvioida objektiivisesti. Tulevaisuudessa menetelmäkehityksessä on syytä käyttää ylimääräisiä WT:n mittauksia interpolaatiomallin validointiin. On myös syytä arvioida interpolaation soveltuvuutta eri tilanteisiin, ja kehittää sitä tarpeen mukaan, jotta se kuvastaisi todellista tilannetta suolla tarkasti. Esimerkiksi Rahman et al. (2017) olivat käyttäneet kriging-interpolointia, jota usein käytetään ympäristötieteissä. Rahman et al. (2017) painottivat tutkimuksessaan menetelmänsä soveltuvan parhaiten avoimille, vain vähän viettäville soille. Yksi merkittävä suomalainen suoluontoyhdistymätyyppi on rinnesuot. Myös tutkimuksemme suo oli viettävä. Menetelmäkehitystä jatkettaessa olisi syytä validointiaineiston avulla tutkia kuinka erilaiset pinnan tai linjan interpolointimenetelmät soveltuvat viettävälle suolle. Lisäksi voitaisiin tutkia LiDAR-aineiston sopivuutta

menetelmän soveltamiseen puustoisilla suokohteilla, joilla näkyvän valon aineistosta luotettavien maanpinnan mallien tuottaminen on helpompaa olosuhteissa, joissa kasvillisuus peittää suon pinnan. Menetelmäkehityksessä voitaisiin myös arvioida ennallistamistoimien vaikutusta suon pintaan ja sitä, miten pinnantaso vaihtelee luonnollisesti WT:n vaihtelun myötä. Näin voitaisiin arvioida, kuinka luotettavaa on käyttää esimerkiksi edellisen mittauskauden kuvauksista tuotettua pintamallia mittauskauden WT:n pinnan interpolointiin.

## 4.5 Yhteenveto

Diplomityön tavoitteena oli tutustua Suomen soihin, niiden ennallistamiseen ja ennallistamisen seurantaan erityisesti hydrologian ja vedenpinnan tason (WT) kannalta. Suomessa on eritelty kaikkiaan yli 100 erilaista suoluontotyyppiä ja luontotyyppiyhdistelmää, joista yli 50 % katsotaan olevan uhanalaisia, erityisesti ojituksen ja maankäytön muutosten johdosta. Ennallistaminen on tärkeä tapa vahvistaa biodiversiteettiä ja parantaa luontotyyppien ja uhanalaisten lajien mahdollisuuksia selvitä. Soiden ennallistamisen tapauksessa pääasiallinen tavoite on saattaa suon vesitalous kohti luonnollista tilaa tukkimalla ja täyttämällä ojituksia ja ohjaamalla vesiä halutuille alueille soilla, ja siten parantaa suolajien selviämismahdollisuuksia ja ohjata sukkessiota kohti soisempaa luontotyyppiä.

Tutkimuksessa käsiteltiin ja analysoitiin kahden vahvasti pohjavesivaikuttaisen suokohteen WT:n monitorointiaineistoa. Kohteet sijaitsivat Olvassuolla, Pohjois-Pohjanmaalla, ja niistä toinen ennallistettiin tutkimuksen ajanjakson aikana, kun toinen toimi luonnontilaisena vertailukohteena. WT:tä monitoroitiin kahden mittauskauden ajan kahdessa pisteessä molemmilla soilla automaattisten tiedonkeruulaitteiden, eli loggerien avulla. Ennallistuskohdelle ja luonnontilaiselle kohdelle laskettujen vedenpinnan syvyyden WTD (engl. *water table depth*) tunnuslukujen perusteella arvioitiin ennallistamisen vaikutuksia. Lisäksi laskettiin prosenttiosuudet, kuinka suuren osan mittauskaudesta WT on ollut suon pinnan yläpuolella, sen pinnan alapuolella, mutta korkeammalla, kuin 20 cm syvyydessä, sekä syvemmällä, kuin 20 cm syvyydessä. Hypoteesina oli, että ennallistamistoimet nostaisivat WT:tä ennallistuskohdella ja vähentäisivät sen vaihtelua WTF luonnontilaisen vertailukohteen vastaavien tasolle. Tutkimuksen perusteella WT nousi ja WTF väheni ennallistamistoimien myötä ennallistuskohdella. Ennallistetun suon yläosassa WT nousi luonnontilaista

vertailukohdetta korkeammalle ja sen alaosassa jäi vertailukohdetta syvemmälle, mutta erot kohteiden WT:ssä olivat vähäisemmät verrattuna ennallistamista edeltävään mittauskauteen. WT:n virhettä tutkimuksessa arvioitiin käsin tehtyjen WT:n tarkastusmittausten avulla. Virhe oli niin suuri, että kohteen ennallistamistoimien riittävyttä ei voitu luotettavasti arvioida. Tutkimuksessa todettiin, että loggeriseurantaa on syytä dokumentoida ja maastomittausten käytäntöjä yhtenäistää hydrologisen seurannan luotettavuuden parantamiseksi. Todettiin myös, että ennallistamisen onnistumisen toteaminen vaatisi pidempää seurantaa ja useampien muuttujien vertailua.

Tutkimuksessa tutustuttiin myös UAS- (engl. *Unmanned Aircraft System*) eli dronekuvaukseen ja sen mahdollisuuksiin ennallistamisen seurannassa. Ennallistamisen hydrologinen seuranta on usein hyvin työlästä ja saattaa rajoittua pistemäiseen WT:n seurantaan, mistä syystä menetelmien kehitys on tärkeää seurannan objektiivisuuden ja luotettavuuden parantamiseksi sekä seurannan helpottamiseksi. Ennallistuskohdelle luotiin mittalinja kahden mittauspisteen välille ilmakuvista tunnistettujen avovesipisteiden kautta. UAS-kuvista tuotetusta pintamallin avulla luotiin mittalinjalle suon pinnan profiili, ja tälle profiilille interpoloitiin WT jokaiselle tutkimuksen ajanjakson päivälle, käyttäen hyväksi oletusta siitä, että vesi myötäilee suolla suon pintaa. Profiilin jokaiselle pisteelle laskettiin WTD:n aikaprosenttiosuudet ja tuotetulle aineistolle laskettiin tilastollisia tunnuslukuja. Hypoteesi oli, että WT on noussut ennallistamistoimien myötä myös koko profiililla. Hypoteesi toteutui, ja mallinnuksen perusteella suo tulvi lähes koko ennallistamista seuraavan mittauskauden koko mittalinjalla. Mallin validoiminen jäi puutteelliseksi validointiaineiston uupumisen takia. Maastohavaintojen perusteella ennallistamista seuraavan tulvimisen ei katsottu vastaavan todellista tilannetta suolla. Interpolointimenetelmässä on kuitenkin potentiaalia, ja menetelmän kehitystä tulisi jatkaa. Jos löydetään hyvä toimintatapa WT:n mallintamiseen, voidaan sillä merkittävästi parantaa ennallistamisen seurannan objektiivisuutta ja helpottaa seurantaa tekevien työtä.



## LÄHDELUETTELO

Aapala, K., Haapalehto, T., Kotiaho, J., Lindholm, T., Rehell, S., Sallantausta, T., Similä, M., Suikki, A., Tahvanainen, T. & Vesterinen, P., 2009. 5 Ennallistettujen soiden seuranta. Teoksessa: Hyvärinen, E. & Aapala, K. (toim.) Metsien ja soiden ennallistamisen sekä harjumetsien paahdeympäristöjen hoidon seurantaohje. Suomi: Metsähallitus, S. 34-64. ISBN 978-952-446-728-5

Aapala, K., Lindholm, T., Sallantausta, T., Similä, M., Tahvanainen, T., Haapalehto, T., Penttinen, J., Salminen, P., Suikki, A. & Vesterinen, P., 2012. Monitoring restored peatlands in Finnish nature reserves. Teoksessa: Lindholm, T. & Heikkilä, R. (toim.) Mires from pole to pole. Helsinki: Finnish Environment Institute, S. 197-204. ISBN 978-952-11-4107-2

Aapala, K., Rehell, S. & Similä, M., (toim.), 2013a. 5 Suoluonnon monimuotoisuus. Teoksessa: Aapala, K., Similä, M. & Penttinen J. (toim.) Ojitettujen soiden ennallistamisopas. Vantaa: Metsähallitus, S. 72-85. ISBN 978-952-295-026-0

Aapala, K., Rehell, S., Similä, M. & Haapalehto, T., 2013b. 2 Ennallistamisen tarve ja tavoitteet. Teoksessa: Aapala, K., Similä, M. & Penttinen J. (toim.) Ojitettujen soiden ennallistamisopas. Vantaa: Metsähallitus, S. 19-23. ISBN 978-952-295-026-0

Ahtiainen, M. & Huttunen, P., 1999. Long-term effects of forestry managements on water quality and loading in brooks. Boreal environment research 4 (2), S. 101-114 [verkkojulkaisu]. Saatavissa: <http://www.borenv.net/BER/pdfs/ber4/ber4-101-114.pdf> [viitattu 14.8.2020]

Ala-aho, P., 2019. Statistical hydrology 488137S Statistical tests [sähköinen luentomateriaali]. Oulun yliopisto: Oulu.

Baldock, D., 1984. Wetland drainage in Europe. International Institute for Environment and Development, Nottingham, UK.

Balluf Inc., 2020. Automation Insights: What is a capacitive sensor? [verkkodokumentti]. Saatavissa: <https://automation-insights.blog/2017/06/07/what-is-a-capacitive-sensor/> [viitattu 25.11.2020]

Bragazza, L. & Gerdol, R., 1999. Hydrology, groundwater chemistry and peat chemistry in relation to habitat conditions in a mire on the South-eastern Alps of Italy. *Plant Ecology* 144 (2), S. 243-256 [verkkojulkaisu]. Saatavissa: <https://www.jstor.org/stable/20050831> [viitattu 9.9.2020]

Brunner, P., Hendricks Franssen, H.-J., Kgotlhang, L., Bauer-Gottwein, P., & Kinzelbach, W., 2007. How can remote sensing contribute in groundwater modeling?. *Hydrogeology Journal* 15 (1), S. 5-18 [verkkojulkaisu]. Saatavissa: <https://doi.org/10.1007/s10040-006-0127-z> [viitattu 10.8.2020]

Cajander, A. K., 1906. Maamme soista ja niiden metsätaloudellisesta merkityksestä. I. Soittemme luonnonhistoria [verkkodokumentti]. Helsinki: J. Simeliuksen perillisten kirjapaino osakeyhtiö. Saatavissa: [https://helda.helsinki.fi/bitstream/handle/1975/8544/1906\\_Cajander\\_MaammeS.pdf?sequence=5&isAllowed=y](https://helda.helsinki.fi/bitstream/handle/1975/8544/1906_Cajander_MaammeS.pdf?sequence=5&isAllowed=y) [viitattu 23.7.2020]

Charman, D., 2002. *Peatlands and Environmental Change*. Chirchester, England: John Wiley and Sons, 301 s. ISBN 0-471-96990-7

Dieleman, C. M., Branfireun, B. A., MacLaughlin, J. W. & Lindo, Z., 2014. Climate change drives a shift in peatland ecosystem plant community: Implications for ecosystem function and stability. *Global Change Biology*, 21 (1), S. 388-395 [verkkolehti]. Saatavissa: <https://doi.org/10.1111/gcb.12643> [viitattu 22.7.2020]

de Roos, S., Turner, D., Lucieer, A. & Bowman, D. M. J. S., 2018. Using Digital Surface Models from UAS Imagery of Fire Damaged *Sphagnum* Peatlands for Monitoring and Hydrological Restoration. *Drones* 2 (4) [verkkojulkaisu]. Saatavissa: <https://doi.org/10.3390/drones2040045> [viitattu 29.10.2020]

Eeronheimo, H., Aapala, K. & Korvenpää, T., 2013. Tietolaatikko 25. Putkilokasvien ja sammalten siirrot soiden ennallistamisen yhteydessä. Teoksessa: Aapala, K., Similä, M. & Penttinen, J. (toim.) *Ojitettujen soiden ennallistamisopas*. Vantaa: Metsähallitus, S. 132-134. ISBN 978-952-295-026-0

Egglesman, R., Heathwaite, A. L., Gross-Braukmann, G., Kuster, E., Naucke, W., Schich, M. & Schweikle, V., 1993. Physical processes and properties of mires. Teoksessa: Heathwaite, A. L. & Gottlich, Kh (toim.). Mires: Process, Exploration and Conservation. Chichester, England: John Wiley and Sons. ISBN-13 978-0471933533

Eskonen, H., 2018. Uhanalaiset palsasuot. Natura: biologian ja maantiedon opettajien liiton julkaisu, 2018 (2) [verkkoartikkeli]. Saatavissa: <http://www.naturehti.fi/2018/05/18/uhanalaiset-palsasuot/> [viitattu 23.7.2020]

European Commission Environment DG, 2020. Hydrology LIFE – Restoring the hydrological integrity of wetland habitats in Finland, LIFE16 NAT/FI/000583 [verkkodokumentti]. Brysseli: European Commission. Saatavissa: [https://ec.europa.eu/environment/life/project/Projects/index.cfm?fuseaction=search.dspPage&n\\_proj\\_id=6290#PD](https://ec.europa.eu/environment/life/project/Projects/index.cfm?fuseaction=search.dspPage&n_proj_id=6290#PD) [viitattu 5.8.2020]

European Commission, 2020a. Environment, Nature and biodiversity, Frequently asked questions on Natura 2000 [verkkodokumentti]. Brysseli: European Commission. Saatavissa: [https://ec.europa.eu/environment/nature/natura2000/faq\\_en.htm](https://ec.europa.eu/environment/nature/natura2000/faq_en.htm) [viitattu 5.8.2020]

European Commission, 2020b. LIFE – History of LIFE [verkkodokumentti]. Brysseli: European Commission. Saatavissa: <https://ec.europa.eu/easme/en/section/life/life-history-life> [viitattu 29.6.2020].

European Commission, 2020c. LIFE programme [verkkodokumentti]. Brysseli: European Commission. Saatavissa: <https://ec.europa.eu/easme/en/life> [viitattu 29.6.2020]

geologia.fi, 2020. Suot [verkkodokumentti]. Saatavissa: <http://www.geologia.fi/index.php/2018/06/04/suot/> [viitattu 3.12.2020]

Gibson, D. J., 1996. Textbook Misconceptions: The Climax Concept of Succession. The American Biology Teacher 58 (3), S. 135-140 [verkkojulkaisu]. Saatavissa: <https://www.jstor.org/stable/4450101> [viitattu 20.8.2020]

Gindraux, S., Boesch, R. & Farinotti, D., 2017. Accuracy Assessment of Digital Surface Models from Unmanned Aerial Vehicles' Imagery on Glaciers. *Remote Sensing* 9 (2) [verkkojulkaisu]. Saatavissa: <https://doi.org/10.3390/rs9020186> [viitattu 29.10.2020]

Haapalehto, T., Kotiaho, J. S., Matilainen, R., & Tahvanainen, T., 2014. The effects of long-term drainage and subsequent restoration on water table level and pore water chemistry in boreal peatlands. *Journal of Hydrology* 519 (Part B), S. 1493-1505 [verkkojulkaisu]. Saatavissa: <https://doi.org/10.1016/j.jhydrol.2014.09.013> [viitattu 10.9.2020]

Heikkilä, H. & Lindholm, T., 1995. 36 The Basis of Mire Restoration in Finland. Teoksessa: Wheeler, B. D., Shaw, S. C., Fojt, W. J. & Robertson, R. A. (toim.) *Restoration of Temperate Wetlands*. Chichester, England: John Wiley & Sons Ltd. S. 549-556. ISBN 0-471-95105-6

Hobbs, N. B., 1986. Mire morphology and the properties and behaviour of some British and foreign peats. *Quarterly Journal of Engineering Geology* 19 (1), S. 7-80.

Holden, J., Chapman, P. J. & Labadz, J. C., 2004. Artificial drainage of peatlands: hydrological and hydrochemical process and wetland restoration. *Progress in Physical Geography: Earth and Environment* 28 (1), S. 95-123 [verkkolehti]. Saatavissa: <https://doi.org/10.1191/0309133304pp403ra> [viitattu 10.8.2020]

Holden, J., Evans, M. G., Burt, T. P. & Horton, M., 2006. Impact of land drainage on peatland hydrology. *Journal of Environmental Quality* 35 (5), S. 1764-1778 [verkkojulkaisu]. Saatavissa: <https://doi.org/10.2134/jeq2005.0477> [viitattu 4.8.2020]

Humboldt State University, 2017. Humboldt State Geospatial Online, GSP 2016 Introduction to remote sensing, Structure from Motion (SfM) [verkkodokumentti]. Saatavissa: [http://gsp.humboldt.edu/OLM/Courses/GSP\\_216\\_Online/lesson8-2/SfM.html](http://gsp.humboldt.edu/OLM/Courses/GSP_216_Online/lesson8-2/SfM.html) [viitattu 28.10.2020]

Hyvärinen, E., & Aapala, K. (toim.), 2009. Metsien ja soiden ennallistamisen sekä harjumetsien paahdeyhmpäristöjen hoidon seurantaohje. Metsähallituksen luonnonsuojelujulkaisuja. Sarja B 118. Metsähallitus. 116 s. ISBN 978-952-446-728-5

Ikkala, L., 2019. Field measurements, site investigations and geotechnological tests: UAV surveys [sähköinen luentomateriaali]. Oulun yliopisto: Oulu.

Ilmatieteen laitos, 2020a. Havaintojen lataus [verkkodokumentti]. Saatavissa: <https://www.ilmatieteenlaitos.fi/havaintojen-lataus> [viitattu 4.11.2020]

Ilmatieteen laitos, 2020b. Ilmatieteen laitos [verkkodokumentti]. Saatavissa: <https://www.ilmatieteenlaitos.fi/ilmatieteen-laitos> [viitattu 1.10.2020]

Ilmatieteen laitos, 2020c. Ilmatieteen laitoksen havaintoasemat [verkkodokumentti]. Saatavissa: <https://www.ilmatieteenlaitos.fi/havaintoasemat> [viitattu 16.9.2020]

Ilmatieteen laitos, 2020d. Miten säätä havainnoidaan Ilmatieteen laitoksessa? [verkkodokumentti]. Saatavissa: <https://www.ilmatieteenlaitos.fi/saahavainnot> [viitattu 16.9.2020]

James, M. R. & Robson, S., 2014. Mitigating systematic error in topographic models derived from UAV and ground-based image networks. *Earth Surface Processes and Landforms* 39 (10), S. 1413-1420 [verkkojulkaisu]. Saatavissa: <https://doi.org/10.1002/esp.3609> [viitattu 28.10.2020]

Jensen, J. & Mathews, A., 2016. Assessment of Image-Based Point Cloud Products to Generate Bare Earth Surface and Estimate Canopy Heights in a Woodland Ecosystem. *Remote Sensing* 8 (1), 50 [verkkojulkaisu]. Saatavissa: <https://doi.org/10.3390/rs8010050> [viitattu 26.10.2020].

Jeziorska, J., 2019. UAS for Wetland Mapping and Hydrological Modeling. *Remote Sensing*, 11 (17) [verkkolehti]. Basel: MDPI AG. Saatavissa: <https://doi.org/10.3390/rs11171997> [viitattu 10.7.2020]

Joensuu, S., 2020. Tapio, Hydrologia-LIFE vesiensuojelun hanke [verkkodokumentti]. Helsinki: Tapio Oy. Saatavissa: <https://tapio.fi/hydrologia-life/> [viitattu 8.7.2020]

Joosten, H., Moen, A., Couwenberg, J. & Tanneberger, F., 2017. 2 Mire diversity in Europe: mire and peatland types. Teoksessa: Joosten, H., Tanneberger, F. & Moen, A. (toim.). *Mires and peatlands of Europe: Status, distribution and conservation*. E. Stuttgart,

Germany: Schweizerbart'sche Verlagsbuchhandlung (Nägele u. Obermiller), S. 5-63.  
ISBN 978-3-510-65383-6

Kaakinen, E., Kokko, A., & Aapala, K., 2012. Assessment of threatened mire habitats in Finland. Teoksessa: Lindholm, T. & Heikkilä, R. (toim.) *Mires from pole to pole*. Helsinki: Finnish Environment Institute, S. 181-196. ISBN 978-952-11-4107-2

Kaakinen, E., Kokko, A., Aapala, K., Autio, O., Eurola, S.†, Hotanen, J.-P., Kondelin, H., Lindholm, T., Nousiainen, H., Rehell, S., Ruuhijärvi, R., Sallantausta, T., Salminen, P., Tahvanainen, T., Tuominen, S., Turunen, J., Vasander, H. & Virtanen, K., 2018a. Suot. Julk.: Kontula, T. & Raunio, A. (toim.). *Suomen ympäristö 5/2018, Suomen luontotyyppien uhanalaisuus 2018. Luontotyyppien punainen kirja – Osa 1: Tulokset ja arvioinnin perusteet [verkkojulkaisu]*. Helsinki: Suomen ympäristökeskus & ympäristöministeriö. ISBN: 978-952-11-4816-3. Saatavissa: <http://julkaisut.valtioneuvosto.fi/handle/10024/161233> [viitattu 10.7.2020]

Kaakinen, E., Kokko, A., Aapala, K., Autio, O., Eurola, S.†, Hotanen, J.-P., Kondelin, H., Lindholm, T., Nousiainen, H., Rehell, S., Ruuhijärvi, R., Sallantausta, T., Salminen, P., Tahvanainen, T., Tuominen, S., Turunen, J., Vasander, H., Virtanen, K., 2018b. Suot. Julk.: Kontula, T. & Raunio, A. (toim.). *Suomen ympäristö 5/2018, Suomen luontotyyppien uhanalaisuus 2018. Luontotyyppien punainen kirja – Osa 2: luontotyyppien kuvaukset [verkkojulkaisu]*. Helsinki: Suomen ympäristökeskus & ympäristöministeriö, S. 117-170. ISBN: 978-952-11-4819-4. Saatavissa: <http://julkaisut.valtioneuvosto.fi/handle/10024/161234> [viitattu 10.7.2020]

Kemp, D. D., 1998. *The environment dictionary*. London: Routledge, 480 s. ISBN 0-41512752-1

Keto-Tokoi, P. & Kuuluvainen, T., 2010. *Suomalainen aarniometsä*. Maahenki, Hämeenlinna. ISBN: 978-952-5870-06-0

Kettridge, N., Turetsky, M. R., Sherwood, J. H., Thompson, D. K., Miller, C. A., Benscoter, B. W., Flannigan, M. D., Wotton, B. M. & Waddington, J. M., 2015. Moderate drop in water table increases peatland vulnerability to post-fire regime shift. *Scientific Reports* 5, S. 1-4 [verkkojulkaisu]. Saatavissa: <https://doi.org/10.1038/srep08063> [viitattu 10.8.2020]

Korhola, A. & Tolonen, K., 2006. The natural history of mires in Finland and the rate of peat accumulation. Teoksessa: Vasander, H. (toim.), 1996. Peatlands in Finland. Helsinki: Finnish Peatland Society. ISBN 952-90-7971-0

Kuhry, P. & Turunen, J., 2006. 3 The Postglacial Development of Boreal and Subarctic Peatlands. Teoksessa: Wieder, R. K. & Vitt, D. H. (toim.). Boreal Peatland Ecosystems, Ecological studies 188. Germany: Spriger-Verlag Berlin Heidelberg, 435 s. ISBN-10 3-540-31912-3

Laine, J., Laiho, R., Minkkinen, K. & Vasander, H., 2006. 15 Forestry and Boreal Peatlands. Teoksessa: Wieder, R. K. & Vitt, D. H. (toim.). Boreal Peatland Ecosystems, Ecological studies 188. Germany: Spriger-Verlag Berlin Heidelberg, 435 s. ISBN-10 3-540-31912-3

Laine, J., Vasander, H. & Laiho, R., 1995. Long-term effects of water level drawdown on the vegetation of drained pine mires in southern Finland. *Journal of Applied Ecology* 32 (4) [verkkojulkaisu]. Saatavissa: <https://www.jstor.org/stable/2404818> [viitattu 4.8.2020]

Lammi, A., Kokko, A., Kuoppala, M., Aroviita, J., Ilmonen, J., Jormola, J., Karonen, M., Kotanen, J., Luotonen, H., Muotka, T., Mykrä, H., Rintanen, T., Sojakka, P., Teeriaho, J., Teppo, A., Toivonen, H., Urho, L. & Vuori, K.-M., 2018. Sisävedet ja rannat. Julk.: Kontula, T. & Raunio, A. (toim.). Suomen ympäristö 5/2018, Suomen luontotyyppien uhanalaisuus 2018. Luontotyyppien punainen kirja – Osa 2: luontotyyppien kuvaukset [verkkojulkaisu]. Helsinki: Suomen ympäristökeskus & ympäristöministeriö, S. 81-115. ISBN: 978-952-11-4819-4. Saatavissa: <http://julkaisut.valtioneuvosto.fi/handle/10024/161234> [viitattu 22.7.2020]

Lappalainen, E., Stén, C.-G. & Häikiö, J., 1984. Opas n:o 12: Turvetutkimuksen maasto-opas [verkkojulkaisu]. Espoo: Geologian tutkimuskeskus, 62 s. ISBN 951-690-192-1. Saatavissa: [http://tupa.gtk.fi/julkaisu/opas/op\\_012.pdf](http://tupa.gtk.fi/julkaisu/opas/op_012.pdf) [viitattu 22.7.2020]

Liikenne- ja viestintävirasto Traficom, 2020a. Droneinfo.fi, EU-droneasetuksen soveltaminen viivästyy [verkkodokumentti]. Saatavissa: [https://www.droneinfo.fi/fi/tiedotteet/6944/eu-droneasetuksen\\_soveltaminen\\_siirtyy](https://www.droneinfo.fi/fi/tiedotteet/6944/eu-droneasetuksen_soveltaminen_siirtyy) [viitattu 28.10.2020]

Liikenne- ja viestintävirasto Traficom, 2020b. Droneinfo.fi, Ohjeita turvalliseen lentämiseen [verkkodokumentti]. Saatavissa: [https://www.droneinfo.fi/fi/nain\\_lennatat\\_turvallisesti](https://www.droneinfo.fi/fi/nain_lennatat_turvallisesti) [viitattu 28.10.2020]

Liikenne- ja viestintävirasto Traficom, 2020c. Droneinfo.fi, Älä lennätä täällä [verkkodokumentti]. Saatavissa: [https://www.droneinfo.fi/fi/ala\\_lennata\\_taalla](https://www.droneinfo.fi/fi/ala_lennata_taalla) [viitattu 28.10.2020]

Lindholm, T., 2013. Miten käsityksemme suoyhdistymistä syntyi, kehittyi ja muovasi näkemyksemme Suomen soista – Sata vuotta A. K. Cajanderin suoklassikosta: Studien über die Moore Finnlands. Suo 64 (2-3) [verkkojulkaisu]. Saatavissa: <http://www.suo.fi/article/9891> [viitattu: 23.7.2020]

Lucieer, A., Turner, D., King, D. H. & Robinson, S. A., 2014. Using an Unmanned Aerial Vehicle (UAV) to capture micro-topography of Antarctic moss beds. International Journal of Applied Earth Observation and Geoinformation, 16 (27 Part A), S. 53-62 [verkkolehti]. Saatavissa: <https://doi.org/10.1016/j.jag.2013.05.011> [viitattu 10.7.2020]

Luken, J. O., 1990. Directing Ecological Succession. 1. painos. London: Chapman and Hall, 251 s. ISBN 0-412-34450-5

Luonnonvarakeskus, 2017. Soiden ojittaminen näkyy vesistöissä yhä enemmän [verkkodokumentti] Saatavissa: <https://www.luke.fi/uutinen/soiden-ujittaminen-nakyy-vesistoissa-yha-enemman/> [viitattu 10.9.2020]

Luontoon.fi, 2020. Olvassuon luonnonsuojelualue [verkkodokumentti]. Saatavissa: <https://www.luontoon.fi/olvassuo> [viitattu 10.9.2020]

Manfreda, S., McCabe, M. F., Miller, P. E., Lucas, R., Madrigal, V. P., Mallinis, G., Ben Dor, E., Helman, D., Estes, L., Ciraolo, G., Müllerová, J., Tauro, F., De Lima, M. I., Maltese, J. L. M. P., Maltese, A., Frances, F., Caylor, K., Kohv, M., Perks, M., Ruiz-Pérez, G., Su, Z., Vico, G. & Toth, B., 2018. On the Use of Unmanned Aerial Systems for Environmental Monitoring. Remote Sensing 10 (4), 641 [verkkojulkaisu]. Saatavissa: <https://doi.org/10.3390/rs10040641> [viitattu 23.10.2020]



Marriot, F. H. C. & Pope, J. A., 1954. Bias in the Estimation of Autocorrelations. *Biometrika* 41(3), S. 390-402. Oxford University Press.

Matese, A., Toscano, P., di Gennaro, S. F., Genesio, L., Vaccari, F. P., Primicerio, J., Belli, C., Zaldei, A., Bianconi, R. & Gioli, B., 2015. Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture. *Remote Sensing*. 7 (3) S. 2971–2990.

Menberu, M. W., 2018. Hydrology of peat-dominated headwater catchments, Theories and empirical analysis of the impacts of anthropogenic disturbance [verkkójulkaisu]. Väitöskirja (TkT). Oulun yliopisto. Saatavissa: <http://jultika.oulu.fi/files/isbn9789526219370.pdf> [viitattu 6.8.2020]

Menberu, M. W., Tahvanainen, T., Marttila, H., Irannezhad, M., Ronkanen, A.-K., Penttinen, J. & Kløve, B., 2016. Water-table-dependent hydrological changes following peatland forestry drainage and restoration: Analysis of restoration success. *Water Resources Research* 52 (5) S. 3742-3760 [verkkójulkaisu]. Saatavissa: <https://doi.org/10.1002/2015WR018578> [viitattu 21.10.2020]

Metsähallitus, 2013. Metsähallituksen selvitys Olvassuon kansallispuiston perustamisedellytyksistä [verkkodokumentti]. Vantaa: Metsähallitus. Saatavissa: <https://julkaisut.metsa.fi/assets/pdf/lp/Muut/olvassuokpselvitys.pdf> [viitattu 10.9.2020]

Metsähallitus, 2020. Projektit, Hydrologia-LIFE [verkkodokumentti]. Vantaa: Metsähallitus. Saatavissa: <https://www.metsa.fi/projekti/hydrologia-life/> [viitattu 8.7.2020]

Metsäkeskus, 2016. Tuki suometsän hoitoon [verkkodokumentti]. Helsinki: Suomen metsäkeskus. Saatavissa: <https://www.metsakeskus.fi/tuki-suometsan-hoitoon> [viitattu 9.9.2020]

Mustamo, P., Hyvärinen, M., Ronkanen, A.-K. & Kløve, B., 2016. Physical properties of peat soils under different land use options. *Soil Use and Management* 32 (3), S. 400-410 [verkkójulkaisu]. Saatavissa: <https://doi.org/10.1111/sum.12272> [viitattu 2.10.2020]

National Ocean Service, 2020. U.S. Department of Commerce, National Oceanic and Atmospheric Administration, National Ocean Service, What is LiDAR? [verkkodokumentti]. Saatavissa: <https://oceanservice.noaa.gov/facts/lidar.html> [viitattu 28.10.2020]

Nieminen, M., Sallantausta, T., Ukonmaanaho, L., Nieminen, T. M. & Sarkkola, S., 2017. Nitrogen and phosphorus concentrations in discharge from drained peatland forests are increasing. *Science of the Total Environment* 609 (19), S. 974-981 [verkkojulkaisu]. Saatavissa: <https://doi.org/10.1016/j.scitotenv.2017.07.210> [viitattu 9.9.2020]

Ojanen, P., 2020. Metsäojituksen vaikutus puuntuotantoon, luontoon ja ympäristöön. *Suovaluma-alueseminaari*, online-seminaari 17.11.2020.

Oulun yliopisto, 2017. Hydrologia LIFE [verkkodokumentti]. Oulu: Oulun yliopisto. Saatavissa <https://www.oulu.fi/water/hydrologicalife> [viitattu 10.7.2020]

Palviainen, M. & Finér, L., 2013. Kunnostusojituksen vaikutus vesistön humuskuormitukseen [verkkodokumentti]. Saatavissa: <https://www.ymparisto.fi/download/noname/%7B482AEFDD-91BB-4837-9068-1988A3C09CD6%7D/94655> [viitattu 12.10.2020]

Penttinen, J., Aapala, K. & Similä, M., 2013. 11 Ennallistamisen vaikutusten seuranta. Teoksessa: Aapala, K., Similä, M. & Penttinen, J. (toim.) *Ojitettujen soiden ennallistamisopas*. Vantaa: Metsähallitus, S. 179-181. ISBN 978-952-295-026-0

Pickett, S. T. A., Collins, S. L. & Armesto, J. J., 1987. Models, mechanisms and pathways of succession. *The Botanical Review* 53 (3), S. 335-371 [verkkojulkaisu]. Saatavissa: <https://www.jstor.org/stable/4354095> [viitattu 7.8.2020]

Pix4D, 2020. 1. Designing the Images Acquisition Plan > b. Computing the Flight Height for a given GSD [verkkodokumentti]. Saatavissa: <https://support.pix4d.com/hc/en-us/articles/202557469-Step-1-Before-Starting-a-Project-1-Designing-the-Image-Acquisition-Plan-b-Computing-the-Flight-Height-for-a-given-GSD> [viitattu 26.10.2020]

Pohjois-Karjalan ELY-keskus, 2020. Natura 2000 tietolomake, Alueen koodi: FI0700046 [verkkodokumentti]. Saatavissa: <http://paikkatieto.ymparisto.fi/natura/2018/tietolomakkeet/FI0700046.pdf> [viitattu 1.10.2020]

Pohjois-Pohjanmaan ELY-keskus ja Kainuun ELY-keskus, 2018. Natura 2000 tietolomake, Alueen koodi: FI1103829 [verkkodokumentti]. Saatavissa: <http://paikkatieto.ymparisto.fi/natura/2018/tietolomakkeet/FI1103829.pdf> [viitattu 8.7.2020]

Price, J. S., Heathwaite, A. L. & Baird, A. J., 2003. Hydrological processes in abandoned and restored peatlands: An overview of management approaches. *Wetlands Ecology and Management* 11 (1), S. 65-83 [verkkojulkaisu]. Saatavissa: <https://link.springer.com/article/10.1023/A%3A1022046409485> [viitattu 2.10.2020]

Price, J. S. & Schlotzhauer, S. M., 1999. Importance of shrinkage and compression in determining water storage changes in peat: the case of a mined peatland. *Hydrological Processes* 13 (16), S. 2591-2601 [verkkojulkaisu]. Saatavissa: [https://doi.org/10.1002/\(SICI\)1099-1085\(199911\)13:16<2591::AID-HYP933>3.0.CO;2-E](https://doi.org/10.1002/(SICI)1099-1085(199911)13:16<2591::AID-HYP933>3.0.CO;2-E) [viitattu 11.8.2020]

Rahman, M. M., McDermid, G. J., Strack, M. & Lovitt, J., 2017. A New Method to Map Groundwater Table in Peatlands Using Unmanned Aerial Vehicles. *Remote Sensing* 9 (10) [verkkolehti]. Basel: MDPI AG. Saatavissa: <https://doi.org/10.3390/rs9101057> [viitattu 10.7.2020]

Rehell, S., 2013a. Tietolaatikko 11. Pohjavedenpinnan tason mittaaminen. Teoksessa: Aapala, K., Similä, M. & Penttinen, J. (toim.) *Ojitettujen soiden ennallistamisopas*. Vantaa: Metsähallitus, S. 56. ISBN 978-952-295-026-0

Rehell, S., 2013b. Tietolaatikko 12. Suoveden virtausmallit erityyppisillä soilla. Teoksessa: Aapala, K., Similä, M. & Penttinen, J. (toim.) *Ojitettujen soiden ennallistamisopas*. Vantaa: Metsähallitus, S. 57-59. ISBN 978-952-295-026-0

Rehell, S., 2019. Suullinen haastattelu. Haastattelijana Lauri Ikkala. 5.7.2019.

Rehell, S., 2020. VS: Olvassuon Kirkaslammen ja Iso Leväniemen suoluontotyypit [yksityinen sähköpostiviesti]. Vastaanottaja: Lassi Päckilä. Lähetetty 29.10.2020 klo. 17.19 (GMT +0200).

Rehell, S., Huttunen, A.†, Kondelin, H. & Laitinen, J., 2012. Development of large-scale aapa mire hydrotopography on land-uplift coastland in northern Finland. Teoksessa: Lindholm, T. & Heikkilä, R. (toim.) Mires from pole to pole. Helsinki: Finnish Environment Institute, S. 39-50. ISBN 978-952-11-4107-2

Rehell, S., Sallantausta, T. & Aapala, K., 2013a. Tietolaatikko 6. Suojelalueiden rajausten puutteet ja niiden korjaaminen. Teoksessa: Aapala, K., Similä, M. & Penttinen, J. (toim.) Ojitettujen soiden ennallistamisopas. Vantaa: Metsähallitus, S. 33-35. ISBN 978-952-295-026-0

Rehell, S., Sallantausta, T., Tahvanainen, T., Haapalehto, T. & Joensuu, S., 2013b. 3 Soiden vesitalous. Teoksessa: Aapala, K., Similä, M. & Penttinen J. (toim.) Ojitettujen soiden ennallistamisopas. Vantaa: Metsähallitus, S. 41-53. ISBN 978-952-295-026-0

Rehell, S., Siekkinen, J. & Leinonen, A., 2013c. Tietolaatikko 24. Korkeustieto ennallistamisen suunnittelussa. Teoksessa: Aapala, K., Similä, M. & Penttinen J. (toim.) Ojitettujen soiden ennallistamisopas. Vantaa: Metsähallitus, S. 128-131. ISBN 978-952-295-026-0

Rehell, S., Similä, M., Vesterinen, P., Ilmonen, J. & Haapalehto, S., 2013d. 6 Ennallistamisen suunnittelu. Teoksessa: Aapala, K., Similä, M. & Penttinen J. (toim.) Ojitettujen soiden ennallistamisopas. Vantaa: Metsähallitus, S. 113-127. ISBN 978-952-295-026-0

Renazezhad, F., Price, J. S., Quinton, W. L., Lennartz, B., Milojevic, T., & Van Cappellen, P., 2016. Structure of peat soils and implications for water storage, flow and solute transport: A review update for geochemists. Chemical Geology 429, S. 75-84 [verkkojulkaisu]. Saatavissa: <https://doi.org/10.1016/j.chemgeo.2016.03.010> [viitattu 10.8.2020]

Riipinen, K., 1993. Suomella on soiden ojituksen maailmanennätys: Suuri osa soista myllätettiin turhaan, eikä luonnontilan palauttaminen käy helposti. Helsingin sanomat [verkkojulkaisu]. Saatavissa: <https://www.hs.fi/kotimaa/art-2000003285196.html> [viitattu 19.11.2020]

Rocheft, L. & Lode, E., 2006. 17 Restoration of Degraded Boreal Peatlands. Teoksessa: Wieder, R. K. & Vitt, D. H. (toim.). Boreal Peatland Ecosystems, Ecological studies 188. Germany: Springer-Verlag Berlin Heidelberg, 435 s. ISBN-10 3-540-31912-3

Ronkanen, A.-K., 2019a. Hydrologiset prosessit. Maan huokoisuus ja veden liike, 3. luentokerta [sähköinen luentomateriaali]. Oulun yliopisto: Oulu.

Ronkanen, A.-K., 2019b. Hydrologiset prosessit. Veden varastoituminen maahan, 4. luentokerta [sähköinen luentomateriaali]. Oulun yliopisto: Oulu.

Rosnell, T. & Honkavaara, E., 2011. Point Cloud Generation from Aerial Image Data Acquired by a Quadrocopter Type Micro Unmanned Aerial Vehicle and a Digital Still Camera. Sensors 12 (1) S. 453-480 [verkkojulkaisu]. Saatavissa: <https://doi.org/10.3390/s120100453> [viitattu 29.10.2020]

Rossi, P., 2019. Hydrogeology and groundwater engineering Lecture 6-7: Groundwater monitoring, Aquifer properties, Pumping tests [sähköinen luentomateriaali]. Oulun yliopisto: Oulu.

Rossi, P., 2019. Hydrogeology and groundwater engineering Lecture 8: Unsaturated layer, Recharge [sähköinen luentomateriaali]. Oulun yliopisto: Oulu

Ruiz-Jaen, M. C. & Aide, T. M., 2005. Restoration Success: How It Is Being Measured? Restoration Ecology 13 (3), S. 569-577 [verkkojulkaisu]. Saatavissa: <https://doi.org/10.1111/j.1526-100X.2005.00072.x> [viitattu 20.10.2020]

Ruuhijärvi, R., 2018. Tietolaatikko 5.4 Ilmastomuutoksen mahdollisia vaikutuksia suokasvillisuudessa. Teoksessa: Kaakinen, E., Kokko, A., Aapala, K., Autio, O., Eurola, S.†, Hotanen, J.-P., Kondelin, H., Lindholm, T., Nousiainen, H., Rehell, S., Ruuhijärvi, R., Sallantausta, T., Salminen, P., Tahvanainen, T., Tuominen, S., Turunen, J., Vasander, H., Virtanen, K., 2018. Suot. Julk.: Kontula, T. & Raunio, A. (toim.). Suomen ympäristö 5/2018, Suomen luontotyyppien uhanalaisuus 2018. Luontotyyppien punainen kirja – Osa 2: luontotyyppien kuvaukset [verkkajulkaisu]. Helsinki: Suomen ympäristökeskus & ympäristöministeriö, S. 150-151. ISBN: 978-952-11-4819-4. Saatavissa: <http://julkaisut.valtioneuvosto.fi/handle/10024/161234> [viitattu 10.7.2020]

Ruusunen, J., 2020. Hydrologia-LIFE, Soiden ennallistaminen – kokemuksia Hydrologia-Life hankkeesta [verkkodokumentti]. Vantaa: Metsähallitus Luontopalvelut. Saatavissa: <https://www.ymparisto.fi/download/noname/%7B066F09FA-4F9B-437B-A55D-26151FF4E166%7D/155673> [viitattu 8.7.2020]

Rönty, H., 2020. Suomessa luotiin valtava ongelma, jonka korjaamiseen menee vuosisatoja: soista tehtiin metsää vuosia, koska sen ilmastovaikutuksia ei tajuttu. *Yle Uutiset* [online], 19.1.2020. Saatavissa: <https://yle.fi/uutiset/3-11157959> [viitattu 9.9.2020]

Sallantausta, T. & Koskinen, M., 2012. Impacts of peatland restoration on nutrient leaching in western and southern Finland. Teoksessa: Teoksessa: Lindholm, T. & Heikkilä, R. (toim.) Mires from pole to pole. Helsinki: Finnish Environment Institute, S. 217-229. ISBN 978-952-11-4107-2

Salonen, V. & Heinonen, P., 2010a. Valokki-nettisuo, Eräitä soihin ja suokasvillisuuteen liittyviä käsitteitä [verkkajulkaisu]. Saatavissa: <http://kasvio.avoin.jyu.fi/suotyypit/sanasto.php> [viitattu 9.9.2020]

Salonen, V. & Heinonen, P., 2010b. Valokki-nettisuo, Korvet [verkkajulkaisu]. Saatavissa: <http://kasvio.avoin.jyu.fi/suotyypit/suotyypit.php?tyyppiid=1> [viitattu 10.9.2020]

Salonen, V. & Heinonen, P., 2010c. Valokki-nettisuo, Letot [verkkajulkaisu]. Saatavissa: <http://kasvio.avoin.jyu.fi/suotyypit/suotyypit.php?tyyppiid=4> [viitattu 10.9.2020]

Salonen, V. & Heinonen, P., 2010d. Valokki-nettisuo, Nevat [verkkojulkaisu]. Saatavissa: <http://kasvio.avoin.jyu.fi/suotyypit/suotyypit.php?tyyppiid=3> [viitattu 10.9.2020]

Salonen, V. & Heinonen, P., 2010e. Valokki-nettisuo, Rämeet [verkkojulkaisu]. Saatavissa: <http://kasvio.avoin.jyu.fi/suotyypit/suotyypit.php?tyyppiid=2> [viitattu 10.9.2020]

Schothorst, C. J., 1977. Subsidence of low moor peat soils in the western Netherlands. *Geoderma* 17 (4), S. 265-291 [verkkojulkaisu]. Saatavissa: [https://doi.org/10.1016/0016-7061\(77\)90089-1](https://doi.org/10.1016/0016-7061(77)90089-1) [viitattu 11.8.2020]

Singh, K. K. & Frazier, A.E., 2018. A meta-analysis and review of unmanned aircraft system (UAS) imagery forterrestrial applications. *International Journal of Remote Sensing* 39 (15-16), S. 1–21 [verkkojulkaisu]. Saatavissa: <https://doi.org/10.1080/01431161.2017.1420941> [viitattu 23.10.2020]

Smithsonian Environmental Research Center, 2020. Biological Invasions [verkkodokumentti]. Saatavissa: <https://serc.si.edu/research/research-topics/biological-invasions> [viitattu 23.11.2020]

Solinst Canada Ltd., 2020. Solinst Levellogger Model 3001, User Guide, Levellogger Series – Software Version 4.4.0 [verkkodokumentti]. Saatavissa: <https://www.solinst.com/products/dataloggers-and-telemetry/3001-levellogger-series/operating-instructions/user-guide/3001-user-guide.pdf> [viitattu 26.8.2020]

Society for Ecological Restoration International Science & Policy Working Group (SER), 2004. The SER International Primer on Ecological Restoration. [www.ser.org](http://www.ser.org) & Tucson: Society for Ecological Restoration International.

Suomen ympäristökeskus, 2020. Ympäristö.fi, Luontotyypit, Luontotyyppien uhanalaisuus, Suot [verkkodokumentti]. Suomen ympäristökeskus SYKE. Saatavissa: [https://www.ymparisto.fi/fi-FI/Luonto/Luontotyypit/Luontotyyppien\\_uhanalaisuus/Suot](https://www.ymparisto.fi/fi-FI/Luonto/Luontotyypit/Luontotyyppien_uhanalaisuus/Suot) [viitattu 21.7.2020]

Suomen ympäristökeskus, 2013. Ympäristö.fi, Suojelualueet, Natura 2000 -alueet, Olvassuo [verkkodokumentti]. Pohjois-Pohjanmaan ELY-keskus ja Kainuun ELY-keskus. Saatavissa: [https://www.ymparisto.fi/fi-FI/Luonto/Suojelualueet/Natura\\_2000\\_alueet/Olvassuo\(4836\)](https://www.ymparisto.fi/fi-FI/Luonto/Suojelualueet/Natura_2000_alueet/Olvassuo(4836)) [viitattu 8.7.2020]

Statistics How To, 2020. What is Root Mean Square Error (RMSE)? [verkkodokumentti]. Saatavissa: <https://www.statisticshowto.com/probability-and-statistics/regression-analysis/rmse-root-mean-square-error/> [viitattu 29.10.2020]

Tahvanainen, T. & Haapalehto, T., 2013. 4 Pintaturpeen ominaisuudet ja turpeen kertyminen. Teoksessa: Aapala, K., Similä, M. & Penttinen J. (toim.) Ojitettujen soiden ennallistamisopas. Vantaa: Metsähallitus, S. 41-53. ISBN 978-952-295-026-0

Tahvanainen, T., Sallantausta, T., Heikkilä, R. & Tolonen, K., 2002. Spatial variation of mire surface water chemistry and vegetation in northeastern Finland. *Annales Botanici Fennici* 39 (3), S. 235-251 [verkkojulkaisu] Saatavissa: <https://www.jstor.org/stable/23726662> [viitattu 14.8.2020]

Tilastokeskus, 2020. Tilastojen ABC, Oppitunti: 4 Tilastollisia perusasioita, Aihe: 4.5 Hajonnan kuvaaminen [verkkodokumentti]. Saatavissa: [https://tilastokoulu.stat.fi/verkkokoulu\\_v2.xql?page\\_type=sisalto&course\\_id=tkoulu\\_tlk&lesson\\_id=4&subject\\_id=5](https://tilastokoulu.stat.fi/verkkokoulu_v2.xql?page_type=sisalto&course_id=tkoulu_tlk&lesson_id=4&subject_id=5) [viitattu 3.11.2020]

Tirri, R., Lehtonen, J., Lemmetyinen, R., Pihakaski, S. & Portin, P., 2001. Biologian sanakirja. Helsinki: Otava, 888 s. ISBN 951-1-17618-8

Turetsky, M. R., Benscoter, B., Page, S., Rein, G., van der Werf, G. R. & Watts, A., 2015. Global vulnerability of peatlands to fire and carbon loss. *Nature Geoscience* 8 (1) [verkkolehti]. Saatavissa: <https://doi.org/10.1038/ngeo2325> [viitattu 6.8.2020]

Turunen, J., 2008. Development of Finnish peatland area and carbon storage 1950-2000. *Boreal Environment Research* 13 (4), S. 319-334 [verkkojulkaisu]. Saatavissa: <https://helda.helsinki.fi/bitstream/handle/10138/234741/ber13-4-319.pdf?sequence=1> [viitattu 6.8.2020]



Trafi, 2018. Trafi Liikenteen turvallisuusvirasto: Määräys TRAFI/334638/03.04.00.00/2017 TRAFI/90924/03.04.00.00/2016 OPS M1-32 [verkkodokumentti]. Saatavissa: [https://arkisto.trafi.fi/filebank/a/1543326521/514c2766eb6f8413b2b0d71032cb4337/32598-OPS\\_M1-32\\_2018\\_fi.pdf](https://arkisto.trafi.fi/filebank/a/1543326521/514c2766eb6f8413b2b0d71032cb4337/32598-OPS_M1-32_2018_fi.pdf) [viitattu 28.10.2020]

TruTrack, 2020. TruTrack WT-HR Water Height Data Logger [verkkodokumentti]. Saatavissa: <https://www.trutrack.com/WT-HR.html> [viitattu 17.9.2020]

Vesterinen, P., Similä, M., Rehell, S., Haapalehto, S., & Perkiö, R., 2013. 7 Ennallistaminen. Teoksessa: Aapala, K., Similä, M. & Penttinen, J. (toim.) Ojitettujen soiden ennallistamisopas. Vantaa: Metsähallitus, S. 138-151. ISBN 978-952-295-026-0

Vitt, D. H., 2006. 2 Functional Charactersitics and Indicators of Boreal Peatlands. Teoksessa: Wieder, R. K. & Vitt, D. H. (toim.), 2006. Boreal Peatland Ecosystems, Ecological studies 188. Germany: Spriger-Verlag Berlin Heidelberg, 435 s. ISBN-10 3-540-31912-3

Walker, P. M. B. (toim.), 1989. Chambers Biology Dictionary. Edinburgh: W & R Chambers LTD and Cambridge University Press, 324 s. ISBN 1-85296-153-8 Pbk

Wieder, R. K. & Vitt, D. H. (toim.), 2006. Boreal Peatland Ecosystems, Ecological studies 188. Germany: Spriger-Verlag Berlin Heidelberg, 435 s. ISBN-10 3-540-31912-3

Ympäristöministeriö, 2019. Luonto, Luonnon monimuotoisuus, Luonnonsuojelualueet, Natura-alueet, Natura 2000 -verkosto turvaa monimuotoisuutta [verkkodokumentti]. Valtioneuvosto: Ympäristöministeriö. Saatavissa: [https://www.ym.fi/fi-FI/Luonto/Luonnon\\_monimuotoisuus/Luonnonsuojelualueet/Naturaalueet](https://www.ym.fi/fi-FI/Luonto/Luonnon_monimuotoisuus/Luonnonsuojelualueet/Naturaalueet) [viitattu 8.7.2020]

Zainuddin, K., Jaffri, M., Zainal, M. & Ghazali, N., 2016. Verification Test on Ability to Use Low-Cost UAV for Quantifying Tree Height [verkkojulkaisu]. *In: Proceedings of the IEEE 12th International Colloquium on Signal Processing & Its Applications*, 4.–6. maaliskuuta 2016. Melaka: Malesia. Saatavissa: [https://www.researchgate.net/profile/Khairulazhar\\_Zainuddin/publication/305508314\\_Verification\\_test\\_on\\_ability\\_to\\_use\\_low-cost\\_UAV\\_for\\_quantifying\\_tree\\_height/links/5b4da708a6fdcc8dae24a57c/Verification-test-on-ability-to-use-low-cost-UAV-for-quantifying-tree-height.pdf](https://www.researchgate.net/profile/Khairulazhar_Zainuddin/publication/305508314_Verification_test_on_ability_to_use_low-cost_UAV_for_quantifying_tree_height/links/5b4da708a6fdcc8dae24a57c/Verification-test-on-ability-to-use-low-cost-UAV-for-quantifying-tree-height.pdf) [viitattu 26.10.2020]

## Liite 1. WT:n interpolaation R-koodi Olvassuo\_interpolation.R

```

# Setting directory
# Setting directory
setwd('/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Interpolation')
# Change language
Sys.setlocale("LC_ALL", "English")
# Load libraries
library("dplyr") # Data handling
library("lubridate") # Date handling
library("ggplot2") # Plotting
# Read ground information with different resolutions
# data005 = read.csv("Ground_Profile_0.05m.txt",sep=";",dec=";",header=T,na.strings="-99.9")
# data01 = read.csv("Ground_Profile_0.1m.txt",sep=";",dec=";",header=T,na.strings="-99.9")
data1 = read.csv("Ground_Profile_1m.txt",sep=";",dec=";",header=T,na.strings="-99.9")
head(data)
tail(data)
# Set x coordinate for the logger 103,the open water surface (83.339, 96.289, 104.650) and the logger 104
logX= c(0,83.339,96.289,104.650,data1[nrow(data1),2]) # 0,169.7869
# Set the initial WT = ELEV - WTD (-0.1679 and -0.2279 respectively) at the loggers and WT = ELEV at open water
logY = c(data1[1,3]-0.1679,128.93,128.85,128.91,c(data1[nrow(data1),3]-0.2279))
log<-data.frame(logY, logX)
# Transform 1 m ground to WT by lowering it by WTD in 103 (-0.1679)
data1$data1_low = data1$FIRST_Z - 0.1679
# Correct the error between the locked points and the open water surface
data1$rownumber = 1:nrow(data1)
data1$corrected = ifelse(data1$rownumber <= 85, data1$data1_low + data1$FIRST_DIST / data1[85,2] * 0.1679, # if data is between
103 and first open water -> correction=0,1679...0
ifelse(data1$rownumber <= 98, 1*data1$FIRST_Z, # if data is between first and second open water -> correction=0
ifelse(data1$rownumber <= 107, 1*data1$FIRST_Z, # if data is between second and third open water ->
correction=0
ifelse(data1$rownumber <= nrow(data1), data1$FIRST_Z - (data1$FIRST_DIST - data1[107,2]) /
(data1[173,2] - data1[107,2]) * 0.2279, NA))))
# if data is between third open water and 104 -> correction 0...0,2279
# Read and treat WTD information in 103 2019
data_10319=read.csv('103_2019_treated_with_logger_installation.csv',header = TRUE, sep = ";", quote = "",
dec = ",", fill = TRUE, comment.char = "",skipNul=FALSE)
head(data_10319)
tail(data_10319)
data_10319$WTLCCm[data_10319$WTLCCm>-4.6]<-NA # Remove outliers outside logger measurement range
data_10319<-data_10319[complete.cases(data_10319), ] # Remove NA rows
# Make date column into data_10319
data_10319$hours <- format(as.POSIXct(data_10319$Date.Time, "%d.%m.%Y %H:%M", tz = ""), format = "%H:%M:%S")
data_10319$date <- format(as.Date(data_10319$Date.Time, "%d.%m.%Y"), format = "%m/%d/%Y")
data_10319$date <- mdy(data_10319$date)
# Daily average from WT at 103 2019
stat <- function(x) c(mean = mean(x))
ag10319 <- aggregate(WTLCCm ~ date, data_10319, stat, na.action = NULL)
# Read and treat WTD information in 103 2020
data_10320=read.csv('103_2020_treated_with_logger_installation.csv', header = TRUE, sep = ";", quote = "",
dec = ",", fill = TRUE, comment.char = "",skipNul=FALSE)
# Make date column into data_10320
data_10320$hours <- format(as.POSIXct(data_10320$Date.Time, "%d.%m.%Y %H:%M", tz = ""), format = "%H:%M:%S")
data_10320$date <- format(as.Date(data_10320$Date.Time, "%d.%m.%Y"), format = "%m/%d/%Y")
data_10320$date <- mdy(data_10320$date)
# Daily average from WT at 103 2020
ag10320 <- aggregate(WTLCCm ~ date, data_10320, stat, na.action = NULL)
# Read and treat WTD information in 104 2019
data_10419=read.csv('104_2019_treated_with_logger_installation.csv',header = TRUE, sep = ";", quote = "",
dec = ",", fill = TRUE, comment.char = "",skipNul=FALSE)
data_10419$WTLCCm[data_10419$WTLCCm>-10]<-NA # Remove outliers outside logger measurement range
data_10419<-data_10419[complete.cases(data_10419), ] # Remove NA rows
# Make a date column into data_104
data_10419$hours <- format(as.POSIXct(data_10419$Date.Time, "%d.%m.%Y %H:%M:%S", tz = ""), format = "%H:%M:%S")
data_10419$date <- format(as.Date(data_10419$Date.Time, "%d.%m.%Y"), format = "%m/%d/%Y")
data_10419$date <- mdy(data_10419$date)
# Daily average from WTD at 104 2019
ag10419 <- aggregate(WTLCCm ~ date, data_10419, stat, na.action = NULL)
# Ag103 and ag104 2019 into equal lengths
ag10419<-ag10419[-c(74:77, 91:100),]
row.names(ag10419) <- 1:nrow(ag10419)
# Read and treat WTD information in 104 2020
data_10420=read.csv('104_2020_treated_with_logger_installation.csv',header = TRUE, sep = ";", quote = "",
dec = ",", fill = TRUE, comment.char = "",skipNul=FALSE)
# Make a date column into data_104
data_10420$hours <- format(as.POSIXct(data_10420$Date.Time, "%d.%m.%Y %H:%M:%S", tz = ""), format = "%H:%M:%S")

```

```

data_10420$date <- format(as.Date(data_10420$Date.Time,"%d.%m.%Y"), format = "%m/%d/%Y")
data_10420$date <- mdy(data_10420$date)
# Daily average from WTD at 104 2020
ag10420 <- aggregate(WTLCcm ~ date, data_10420, stat, na.action = NULL)
### Corrected WT tied into 103 and 104 values for every day (Interpolation) 2019
# 1m WT transformed into every data point at 103
WT10319<-ag10319$WTLCcm/100 # Vector of daily avg WTD at 103 [m]
COR19<-(data1$corrected+0.1679)-data1$FIRST_Z # Vector from corrected values: WTD when WTD at 103 is 0 [m]
# Make a matrix COR-WT103 and diminish every 103 measurement out of every corrected value
COR_10319<-matrix(rep(0,length(WT10319)*length(COR19)), nrow=(length(WT10319)))
for(i in 1:length(WT10319)){
  for(j in 1:length(COR19)){
    COR_10319[i,j] <- WT10319[i]+COR19[j]
  }
}
# Test
COR19+(ag10319[1,2]/100)-COR_10319[1,]
COR19+(ag10319[2,2]/100)-COR_10319[2,]
COR19+(ag10319[3,2]/100)-COR_10319[3,]
# Works
WT10419<-ag10419$WTLCcm/100 # Vector with daily average at 104 as m
# Interpolate Corrected - 103 so that tail is at 104 measurement into new matrix CORRECTED
CORRECTED19<-matrix(rep(0,length(WT10419)*length(COR19)), nrow=(length(WT10419)))
for(i in 1:length(WT10419)){
  for(j in 1:length(COR19)){
    CORRECTED19[i,j] <- (COR_10319[i,j] + (data1[j,2]/data1[173,2])*(WT10419[i]-COR_10319[i,173]))
  }
}
# Test
CORRECTED19[1,173]-WT10419
CORRECTED19[1,]-WT10319
# Last row of CORRECTED matches with WT104, first row of CORRECTED matches with WT103
# Turn CORRECTED matrix into data frame
CORRECTED19<-as.data.frame(CORRECTED19)
# Add dates as names for COR_103 columns
names <- names(CORRECTED19)
name_vec <- setNames(as.character(names), as.character(data1$FIRST_DIST))
CORRECTED19 <- CORRECTED19 %>% rename(!!!name_vec)
CORRECTED19 <- cbind(ag10319$date, CORRECTED19)
## ----- Statistical analysis -----
# Min, max, mean, median, sd of complete data set
max(CORRECTED19[,2:ncol(CORRECTED19)], na.rm=TRUE)
min(CORRECTED19[,2:ncol(CORRECTED19)], na.rm=TRUE)
mean( as.matrix(CORRECTED19[,2:91]), na.rm=TRUE )
median( as.matrix(CORRECTED19[,2:91]), na.rm=TRUE)
# Percentages at levels >0, 0...-20, <(-20)
# Create data.frame for each FIRST_DIST points percentage value of time at certain level
over0<- rep(0, nrow(data1))
PERC19 <- data.frame(FIRST_DIST=data1$FIRST_DIST, over0=over0, zero20=over0, below20=over0, min=over0, max=over0,
  mean=over0, median=over0, sd=over0)
# WTD above ground (>0)
for(i in 2:ncol(CORRECTED19)){
  vect<-CORRECTED19[,i]
  vect<-vect[!is.na(vect)]
  PERC19[i-1,2]<-length(vect[vect > 0])/length(vect)*100
}
# WTD 0...-20cm
for(i in 2:ncol(CORRECTED19)){
  vect<-CORRECTED19[,i]
  vect<-vect[!is.na(vect)]
  PERC19[i-1,3]<-(length(vect[vect > -0.20]) - length(vect[vect > 0]))/length(vect)*100
}
# WTD < -20cm
for(i in 2:ncol(CORRECTED19)){
  vect<-CORRECTED19[,i]
  vect<-vect[!is.na(vect)]
  PERC19[i-1,4]<-length(vect[vect < -0.20])/length(vect)*100
}
# Statistical values for each FIRST_DIST
# Min
for(i in 2:ncol(CORRECTED19)){
  vect<-CORRECTED19[,i]
  vect<-vect[!is.na(vect)]
  PERC19[i-1,5]<-min(vect)
}
# Max
for(i in 2:ncol(CORRECTED19)){
  vect<-CORRECTED19[,i]
  vect<-vect[!is.na(vect)]

```

```

    PERC19[i-1,6]<-max(vect)
  }
  # Mean
  for(i in 2:ncol(CORRECTED19)){
    vect<-CORRECTED19[,i]
    vect<-vect[!is.na(vect)]
    PERC19[i-1,7]<-mean(vect)
  }
  # Median
  for(i in 2:ncol(CORRECTED19)){
    vect<-CORRECTED19[,i]
    vect<-vect[!is.na(vect)]
    PERC19[i-1,8]<-median(vect)
  }
  # Standard distribution
  for(i in 2:ncol(CORRECTED19)){
    vect<-CORRECTED19[,i]
    vect<-vect[!is.na(vect)]
    PERC19[i-1,9]<-sd(vect)
  }
  ## ----- Plotting -----
  # Plot 1m resolution ground section with tie points and corrected wt
  Ground19 <- ggplot() +
    geom_line(aes(x=data1$FIRST_DIST, y=data1$corrected, color="Interpoloitu WT"))+
    geom_line(data=data1, aes(x=FIRST_DIST, y=FIRST_Z, color="Suon pinta"))+
    geom_point(aes(x=log$logX, y=log$logY, color="Sidontapisteeet"))+
    theme_classic()+
    theme(legend.title=element_blank(), legend.position = "bottom",
          axis.text.x=element_text(angle=60, hjust=1))+
    labs(x = "Leikkaus [m]", y = "m mpy")+
    scale_color_manual(values = c("Suon pinta" = "black", "Interpoloitu WT"="blue",
                                   "Sidontapisteeet"="orange")) +
    scale_y_continuous(limits=c(127.5,132.5), breaks=seq(128,132,0.5))+
    scale_x_continuous(breaks=seq(0,170,5))
  Ground19
  # Max WTD at 2019
  rowSums19<-rowSums(CORRECTED19[,2:ncol(CORRECTED19)])
  max(rowSums19)
  max19<-t(CORRECTED19[56,2:ncol(CORRECTED19)])+data1$FIRST_Z
  # Min WTD at 2019
  min(rowSums19)
  min19<-t(CORRECTED19[37,2:ncol(CORRECTED19)])+data1$FIRST_Z
  # Plot 5cm ground section with average wt, max and min wt at 2019
  WT19prof <- ggplot() +
    geom_line(aes(x=data1$FIRST_DIST, y=max19, color="WT:n maksimi"), linetype="longdash")+
    geom_line(aes(x=data1$FIRST_DIST, y=min19, color="WT:n minimi"), linetype="longdash")+
    geom_line(aes(x=data1$FIRST_DIST, y=(PERC19$mean+data1$FIRST_Z), color="WT:n keskiarvo"))+
    geom_line(data=data1, aes(x=FIRST_DIST, y=FIRST_Z, color="Suon pinta"))+
    theme_classic()+
    theme(legend.title=element_blank(), legend.position = "bottom",
          axis.text.x=element_text(angle=60, hjust=1))+
    labs(x = "Leikkaus [m]", y = "m mpy")+
    scale_color_manual(values = c("Suon pinta" = "black",
                                   "WT:n keskiarvo" = "orange", "WT:n maksimi"="blue",
                                   "WT:n minimi"="red")) +
    scale_y_continuous(limits=c(127.5,132.5), breaks=seq(128,132,0.5))+
    scale_x_continuous(breaks=seq(0,170,5))
  WT19prof
  # Column plot WTD percentages for each point
  Time19 <- ggplot()+
    geom_col(aes(x=data1$FIRST_DIST, y=(PERC19$zeroto20+PERC19$below20+PERC19$over0), color="WTD > 0cm"))+
    geom_col(aes(x=data1$FIRST_DIST, y=(PERC19$zeroto20+PERC19$below20), color="0 < WTD < -20cm"))+
    geom_col(aes(x=data1$FIRST_DIST, y=PERC19$below20, color="WTD < -20cm"))+
    theme_classic()+
    theme(legend.title=element_blank(), legend.position = "top", axis.title.x=element_blank(),
          axis.text.x=element_text(angle=60, hjust=1))+
    scale_color_manual(values=c("WTD > 0cm"="blue", "0 < WTD < -20cm"="green",
                                   "WTD < -20cm"="red", "Keskiarvo"="black"))+
    labs(x = "Leikkaus [m]", y = "Aikaprosenttiosuus")+
    scale_x_continuous(breaks=seq(0,170,5))
  Time19
  # The two previous combined
  library(patchwork)
  Time19 / Ground19 +plot_layout(heights = c(0.5, 1))
  ##### Corrected WT tied into 103 and 104 values for every day (Interpolation) 2020
  # 1m WT transformed into every data point at 103
  WT10320<-ag10320$WTLcCm/100 # Vector of daily avg WTD at 103 [m]
  COR20<-(data1$corrected+0.1679)-data1$FIRST_Z # Vector from corrected values: WTD when WTD at 103 is 0 [m]
  plot(data1$FIRST_DIST, COR20, type="l")

```

```

# Make a matrix COR-WT103 and diminish every 103 measurement out of every corrected value
COR_10320<-matrix(rep(0,length(WT10320)*length(COR20)), nrow=(length(WT10320)))
for(i in 1:length(WT10320)){
  for(j in 1:length(COR20)){
    COR_10320[i,j] <- WT10320[i]+COR20[j]
  }
}
# Test
COR20+(ag10320[1,2]/100)-COR_10320[1,]
COR20+(ag10320[2,2]/100)-COR_10320[2,]
COR20+(ag10320[3,2]/100)-COR_10320[3,]
# If zero vector, works
WT10420<-ag10420$WTLcmm/100 # Vector with daily average at 104 as m
# Interpolate Corrected - 103 so that tail is at 104 measurement into new matrix CORRECTED
CORRECTED20<-matrix(rep(0,length(WT10420)*length(COR20)), nrow=(length(WT10420)))
for(i in 1:length(WT10420)){
  for(j in 1:length(COR20)){
    CORRECTED20[i,j] <- (COR_10320[i,j] + (data1[j,2]/data1[173,2])*(WT10420[i]-COR_10320[i,173]))
  }
}
# Test
CORRECTED20[,173]-WT10420
CORRECTED20[,1]-WT10320
# Last row of CORRECTED matches with WT104, first row of CORRECTED matches with WT103
# Turn CORRECTED matrix into data frame
CORRECTED20<-as.data.frame(CORRECTED20)
# Add dates as names for COR_103 columns
names <- names(CORRECTED20)
name_vec <- setNames(as.character(names), as.character(data1$FIRST_DIST))
CORRECTED20 <- CORRECTED20 %>% rename(!!!name_vec)
CORRECTED20 <- cbind(ag10320$date, CORRECTED20)
## ----- Statistical analysis -----
# Min, max, mean, median, sd of complete data set
max(CORRECTED20[,2:ncol(CORRECTED20)], na.rm=TRUE)
min(CORRECTED20[,2:ncol(CORRECTED20)], na.rm=TRUE)
mean( as.matrix(CORRECTED20[,2:91]), na.rm=TRUE )
median( as.matrix(CORRECTED20[,2:91]), na.rm=TRUE)
# Percentages at levels >0, 0...-20, <(-20)
# Create data.frame for each FIRST_DIST points percentage value of time at certain level
over0<- rep(0, nrow(data1))
PERC20 <- data.frame(FIRST_DIST=data1$FIRST_DIST, over0=over0, zero20=over0, below20=over0, min=over0, max=over0,
  mean=over0, median=over0, sd=over0)
# WTD above ground (>0)
for(i in 2:ncol(CORRECTED20)){
  vect<-CORRECTED20[,i]
  vect<-vect[!is.na(vect)]
  PERC20[i-1,2]<-length(vect[vect > 0])/length(vect)*100
}
# WTD 0...-20cm
for(i in 2:ncol(CORRECTED20)){
  vect<-CORRECTED20[,i]
  vect<-vect[!is.na(vect)]
  PERC20[i-1,3]<-(length(vect[vect > -0.20]) - length(vect[vect > 0]))/length(vect)*100
}
# WTD < -20cm
for(i in 2:ncol(CORRECTED20)){
  vect<-CORRECTED20[,i]
  vect<-vect[!is.na(vect)]
  PERC20[i-1,4]<-length(vect[vect < -0.20])/length(vect)*100
}
# Statistical values for each FIRST_DIST
# Min
for(i in 2:ncol(CORRECTED20)){
  vect<-CORRECTED20[,i]
  vect<-vect[!is.na(vect)]
  PERC20[i-1,5]<-min(vect)
}
# Max
for(i in 2:ncol(CORRECTED20)){
  vect<-CORRECTED20[,i]
  vect<-vect[!is.na(vect)]
  PERC20[i-1,6]<-max(vect)
}
# Mean
for(i in 2:ncol(CORRECTED20)){
  vect<-CORRECTED20[,i]
  vect<-vect[!is.na(vect)]
  PERC20[i-1,7]<-mean(vect)
}

```

```

# Median
for(i in 2:ncol(CORRECTED20)){
  vect<-CORRECTED20[,i]
  vect<-vect[!is.na(vect)]
  PERC20[i-1,8]<-median(vect)
}
# Standard distribution
for(i in 2:ncol(CORRECTED20)){
  vect<-CORRECTED20[,i]
  vect<-vect[!is.na(vect)]
  PERC20[i-1,9]<-sd(vect)
}
# Check if WT data mean follows natural distribution
hist(PERC19$mean)
hist(PERC20$mean)
# Mann-Whitney U-test for 2020 and 2019 data means
wilcox.test(PERC19$mean, PERC20$mean,
  alternative = "less",
  mu = 0, paired = FALSE, exact = TRUE, correct = TRUE,
  conf.int = TRUE, conf.level = 0.95)
# Check if WT data median follows natural distribution
hist(PERC19$median)
hist(PERC20$median)
# Mann-Whitney U-test for 2020 and 2019 data median
wilcox.test(PERC19$median, PERC20$median,
  alternative = "less",
  mu = 0, paired = FALSE, exact = TRUE, correct = TRUE,
  conf.int = TRUE, conf.level = 0.95)
# Plotting
# Max WTD at 2019
rowSums20<-rowSums(CORRECTED20[,2:ncol(CORRECTED20)])
max(rowSums20)
max20<-t(CORRECTED20[142,2:ncol(CORRECTED20)])+data1$FIRST_Z
# Min WTD at 2019
min(rowSums20)
min20<-t(CORRECTED20[42,2:ncol(CORRECTED20)])+data1$FIRST_Z
# Plot ground section with average wt, max and min wt at 2020
Ground20 <- ggplot() +
  geom_line(aes(x=data1$FIRST_DIST, y=max20, color="WT:n maksimi"), linetype="longdash")+
  geom_line(aes(x=data1$FIRST_DIST, y=min20, color="WT:n minimi"), linetype="longdash")+
  geom_line(aes(x=data1$FIRST_DIST, y=(PERC20$mean+data1$FIRST_Z), color="WT:n keskiarvo"))+
  geom_line(data=data1, aes(x=FIRST_DIST, y=FIRST_Z, color="Suon pinta"))+
  theme_classic()+
  theme(legend.title=element_blank(), legend.position = "bottom",
    axis.text.x=element_text(angle=60, hjust=1))+
  labs(x = "Leikkaus [m]", y = "m mpy") +
  scale_linetype_manual(values=c("longdash"))+
  scale_color_manual(values = c( "Suon pinta" = "black",
    "WT:n keskiarvo" = "orange", "WT:n maksimi"="blue",
    "WT:n minimi"="red"))+
  scale_y_continuous(limits=c(127.5,132.5), breaks=seq(128,132,0.5))+
  scale_x_continuous(breaks=seq(0,170,5))
Ground20
# Column plot WTD percentages for each point
Time20 <- ggplot()+
  geom_col(aes(x=data1$FIRST_DIST, y=(PERC20$zeroto20+PERC20$over0), color="WTD > 0cm"))+
  geom_col(aes(x=data1$FIRST_DIST, y=(PERC20$zeroto20), color="0 < WTD < -20cm"))+
  theme_classic()+
  theme(legend.title=element_blank(), legend.position = "top",
    axis.text.x=element_text(angle=60, hjust=1))+
  scale_color_manual(values=c("WTD > 0cm"="blue", "0 < WTD < -20cm"="green"))+
  labs(x = "Leikkaus [m]", y = "Aikaprosenttiosuus")+
  scale_x_continuous(breaks=seq(0,170,5))
Time20
# The two previous combined
library(patchwork)
Time20 / Ground20 +plot_layout(heights = c(0.5, 1))

```

## Liite 2. Loggerin 101 datan käsittelyn R-koodi data plotter 101.R

```

library(lubridate) # Date and time handling
library(dplyr) # Data handling
library(ggplot2) # Plotting package
library(patchwork) # To display 2 charts together
library(hrbrthemes) # Additional themes for ggplot2
# Set working directory
setwd("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data plotting/101")
# Read WT data
data_WT19 <- read.csv("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data
plotting/101/101_2019_treated_with_logger_installation.csv",
  header = TRUE, sep = ";", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
data_WT20 <- read.csv("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data
plotting/101/101_2020_treated_with_logger_installation.csv",
  header = TRUE, sep = ";", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
any(is.na(data_WT20$WTLCCm))
any(is.na(data_WT19$WTLCCm))
any(is.infinite(data_WT20$WTLCCm))
any(is.infinite(data_WT19$WTLCCm))
# Check if WT data follows natural distribution
hist(data_WT19$WTLCCm)
hist(data_WT20$WTLCCm)
# Create a function for calculating daily average
stat <- function(x) c(mean = mean(x))
# Aggregate WTD into daily mean values into new dataset
data_WT19$Hours <- format(as.POSIXct(data_WT19$Date.Time, "%d.%m.%Y %H:%M", tz = ""), format = "%H:%M:%S") #
Add time column
data_WT19$date <- format(as.Date(data_WT19$Date.Time, "%d.%m.%Y"), format = "%m/%d/%Y") # Add date column
data_WT20$Hours <- format(as.POSIXct(data_WT20$Date.Time, "%d.%m.%Y %H:%M", tz = ""), format = "%H:%M:%S") #
Add time column
data_WT20$date <- format(as.Date(data_WT20$Date.Time, "%d.%m.%Y"), format = "%m/%d/%Y") # Add date column
agWTD19 <- aggregate(WTLCCm ~ date, data_WT19, stat)
agWTD20 <- aggregate(WTLCCm ~ date, data_WT20, stat)
# Read precipitation grid data
data_PtG19 <- read.delim("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data plotting/101/101_logger_PT_2019_gridded.txt",
  header = TRUE, sep = "", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
data_PtG20 <- read.delim("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data plotting/101/101_logger_PT_2020_gridded.txt",
  header = TRUE, sep = "", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
# Aggregate Pout and Tout into mean values into new dataset
data_PtG19$date <- as.Date(data_PtG19$dateOut, "%d.%m.%Y")
data_PtG20$date <- as.Date(data_PtG20$dateOut, "%Y-%m-%d")
agPg19 <- aggregate(Pout ~ date, data_PtG19, stat)
agTg19 <- aggregate(Tout ~ date, data_PtG19, stat)
agPg20 <- aggregate(Pout ~ date, data_PtG20, stat)
# Create subsets for measurement season
subPg19 <- agPg19[169:289,]
subTg19 <- agTg19[183:289,]
subPg20 <- agPg20[126:287,]
# Sum of P for measurement season
sum(subPg19$Pout)
sum(subPg20$Pout)
# Avg of T for measurement season
mean(subTg19$Tout)
# Read precipitation data from closest station
data_Ps19 <- read.csv("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Utajärvi_Särkijärvi_2019.csv",
  header = TRUE, sep = ";", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
data_Ps20 <- read.csv("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Utajärvi_Särkijärvi_2020.csv",
  header = TRUE, sep = ";", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
# Aggregate sademäärä_mm into mean values into new dataset
data_Ps19$date <- as.Date(with(data_Ps19, paste(Vuosi, Kk, Pv, sep="-")), "%Y-%m-%d")
data_Ps20$date <- as.Date(with(data_Ps20, paste(Vuosi, Kk, Pv, sep="-")), "%Y-%m-%d")
agPs19 <- aggregate(Sademäärä_mm ~ date, data_Ps19, stat)
agSs19 <- aggregate(Lumensyvyys_cm ~ date, data_Ps19, stat)
agPs20 <- aggregate(Sademäärä_mm ~ date, data_Ps20, stat)
agSs20 <- aggregate(Lumensyvyys_cm ~ date, data_Ps20, stat)
# Replace -1 values with 0 value in agPs data
agPs19[agPs19<0]<-0
agSs19[agSs19<0]<-0
agPs20[agPs20<0]<-0

```



```

agSs20[agSs20<0]<-0
# Create a subset for time period
subPs19 <- agPs19[169:289,]
subSs19 <- agSs19[169:289,]
subSs19[subSs19==0]<-NA
subPs20 <- agPs20[126:287,]
subSs20 <- agSs20[126:287,]
subSs20[subSs20==0]<-NA
# Check data has a date format column
str(agWTD19)
agWTD19$date <- mdy(agWTD19$date)
str(agWTD20)
agWTD20$date <- mdy(agWTD20$date)
str(subPs19)
str(subPs20)
str(subSs19)
str(subSs20)
str(subPg19)
str(subPg20)
str(subTg19)
str(subTg20)
str(data_WT19)
data_WT19$date <- mdy(data_WT19$date)
str(data_WT20)
data_WT20$date <- mdy(data_WT20$date)
# ----- WTD statistical analysis -----
# min, max, mean, median, sd 2019
maxWTD19 <- max(data_WT19$WTLCcm)
maxWTD19
minWTD19 <- min(data_WT19$WTLCcm)
minWTD19
meanWTD19 <- mean(data_WT19$WTLCcm)
meanWTD19
medianWTD19 <- median(data_WT19$WTLCcm)
medianWTD19
sdWTD19 <- sd(data_WT19$WTLCcm)
sdWTD19
# min, max, mean, median, sd 2020
maxWTD20 <- max(data_WT20$WTLCcm)
maxWTD20
minWTD20 <- min(data_WT20$WTLCcm)
minWTD20
meanWTD20 <- mean(data_WT20$WTLCcm)
meanWTD20
medianWTD20 <- median(data_WT20$WTLCcm)
medianWTD20
sdWTD20 <- sd(data_WT20$WTLCcm)
sdWTD20
# 2019
vect<-data_WT19$WTLCcm
sum(0<vect)/length(vect)*100 # % of time above ground (WTD>0cm)
(length(vect[vect > -20]) - length(vect[vect > 0]))/length(vect)*100 # % of time between 0...-20cm
sum(-20>vect)/length(vect)*100 # % of time below -20cm
# 2020
vect<-data_WT20$WTLCcm
sum(0<vect)/length(vect)*100 # % of time above ground (WTD>0cm)
(length(vect[vect > -20]) - length(vect[vect > 0]))/length(vect)*100 # % of time between 0...-20cm
sum(-20>vect)/length(vect)*100 # % of time below -20cm
# ----- PLOTTING -----
# Average WTD
# Lineplot average WTD agWTD
avgWTD19 <- ggplot(agWTD19, aes(x=date, y=WTLCcm)) +
  geom_line() +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous( limits=c(-15, 10), breaks=seq(-15,20,5))+
  geom_hline(yintercept=0, linetype="dashed", color = "black")
avgWTD19
avgWTD20 <- ggplot(agWTD20, aes(x=date, y=WTLCcm)) +
  geom_line() +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous( limits=c(-15, 10), breaks=seq(-15,20,5))+
  geom_hline(yintercept=0, linetype="dashed", color = "black")
avgWTD20
# Boxplot average WTD agWTD
avgWTDbox19 <- ggplot(agWTD19, aes(y=WTLCcm)) +

```

```

geom_boxplot(outlier.colour="black", outlier.shape=1,
             outlier.size=2, notch=FALSE)+
theme_classic()+
theme(axis.ticks.x = element_blank(), axis.text.x = element_blank()) +
scale_y_continuous(name="WTD päivakohtainen keskiarvo cm", limits=c(-15, 10), breaks=seq(-15,10,5))
avgWTDbox19
avgWTDbox20 <- ggplot(agWTD20, aes(y=WTLcmm)) +
  geom_boxplot(outlier.colour="black", outlier.shape=1,
              outlier.size=2, notch=FALSE)+
  theme_classic()+
  theme(axis.ticks.x = element_blank(), axis.text.x = element_blank()) +
  scale_y_continuous(name="WTD päivakohtainen keskiarvo cm", limits=c(-15, 10), breaks=seq(-15,10,5))
avgWTDbox20
# Boxplot and lineplot side by side
avgWTDbox19+avgWTD19+plot_layout(widths = c(0.5, 5))
avgWTDbox20+avgWTD20+plot_layout(widths = c(0.5, 5))
# Full WTD dataset
# Lineplot full WTD dataset
fullWTD19 <- ggplot(data_WT19, aes(x=date, y=WTLcmm)) +
  geom_point(size=1, shape=1)+
  geom_line(size=0.4) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-15, 10), breaks=seq(-15,10,5))+
  geom_hline(yintercept=0, linetype="dashed", color = "black")
fullWTD19
fullWTD20 <- ggplot(data_WT20, aes(x=date, y=WTLcmm)) +
  geom_point(size=1, shape=1)+
  geom_line(size=0.4) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-15, 10), breaks=seq(-15,10,5))+
  geom_hline(yintercept=0, linetype="dashed", color = "black")
fullWTD20
# Boxplot full WTD dataset
fullWTDbox19 <- ggplot(data_WT19, aes(y=WTLcmm)) +
  geom_boxplot(outlier.colour="black", outlier.shape=1,
              outlier.size=2, notch=FALSE)+
  theme_classic()+
  theme(axis.ticks.x = element_blank(), axis.text.x = element_blank()) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-15, 10), breaks=seq(-15,10,5))
fullWTDbox19
fullWTDbox20 <- ggplot(data_WT20, aes(y=WTLcmm)) +
  geom_boxplot(outlier.colour="black", outlier.shape=1,
              outlier.size=2, notch=FALSE)+
  theme_classic()+
  theme(axis.ticks.x = element_blank(), axis.text.x = element_blank()) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-15, 10), breaks=seq(-15,10,5))
fullWTDbox20
# Boxplot and lineplot side by side
fullWTDbox19+fullWTD19+plot_layout(widths = c(0.5, 5))
fullWTDbox20+fullWTD20+plot_layout(widths = c(0.5, 5))
# Air temperature from grid Tg
# Plot air temperature from grid subTg
Tg19 <- ggplot(subTg19, aes(x=date, y=Tout)) +
  geom_line() +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Ilman lämpötila degC", limits=c(-5, 25), breaks=seq(-5,25,5))
Tg19
# Precipitation from grid Pg
# Column plot precipitation from grid Pg
Pg19 <- ggplot(subPg19, aes(x=date, y=Pout)) +
  geom_col() +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Sademäärä mm", limits=c(-0, 30), breaks=seq(0,30,2))
Pg19
Pg20 <- ggplot(subPg20, aes(x=date, y=Pout)) +
  geom_col() +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Sademäärä mm", limits=c(-0, 30), breaks=seq(0,30,2))
Pg20

```

```

# Avg WTD, Tg & Pg in same chart
WTDavgPg19 <- ggplot() +
  geom_col(color="blue", data=subPg19, aes(x=date, y=Pout)) +
  geom_line(data=agWTD19, aes(x=date, y=WTLCCm)) +
  geom_line(data=subTg19, aes(x=date, y=Tout), linetype="dashed") +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(legend.position="top", axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.24),
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-15, 30), breaks=seq(-15,30,5),
                     sec.axis=sec_axis(~., name="Sademäärä mm, ilman lämpötila degC", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
WTDavgPg19
WTDavgPg20 <- ggplot() +
  geom_col(color="blue", data=subPg20, aes(x=date, y=Pout)) +
  geom_line(data=agWTD20, aes(x=date, y=WTLCCm)) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(legend.position="top", axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.24),
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-15, 30), breaks=seq(-15,30,5),
                     sec.axis=sec_axis(~., name="Sademäärä mm", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
WTDavgPg20
# WTD, Tg & Pg in same chart
WTDPg19 <- ggplot() +
  geom_col(color="blue", data=subPg19, aes(x=date, y=Pout)) +
  geom_line(data=data_WT19, aes(x=date, y=WTLCCm), size=0.3) +
  geom_point(data=data_WT19, aes(x=date, y=WTLCCm), size=1, shape=1)+
  geom_line(linetype="dashed", data=subTg19, aes(x=date, y=Tout)) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.24), legend.position="top",
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-15, 30), breaks=seq(-15,30,5),
                     sec.axis=sec_axis(~., name="Sademäärä mm, ilman lämpötila degC", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
WTDPg19
WTDPg20 <- ggplot() +
  geom_col(color="blue", data=subPg20, aes(x=date, y=Pout)) +
  geom_line(data=data_WT20, aes(x=date, y=WTLCCm), size=0.3) +
  geom_point(data=data_WT20, aes(x=date, y=WTLCCm), size=1, shape=1)+
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.24), legend.position="top",
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-15, 30), breaks=seq(-15,30,5),
                     sec.axis=sec_axis(~., name="Sademäärä mm", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
WTDPg20
# Precipitation from closest station Ps
# Column plot precipitation from closest station subPs
Ps19 <- ggplot() +
  geom_col(color="blue", data=subPs19, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs19, aes(x=date, y=Lumensyvyys_cm))+
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d")+
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Sademäärä mm, lumensyvyys cm", limits=c(-0, 30), breaks=seq(0,30,2))
Ps19
Ps20 <- ggplot() +
  geom_col(color="blue", data=subPs20, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs20, aes(x=date, y=Lumensyvyys_cm))+
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d")+
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Sademäärä mm, lumensyvyys cm", limits=c(-0, 30), breaks=seq(0,30,2))
Ps20
# Avg WTD & Ps in same chart
avgWTDPs9 <- ggplot() +
  geom_col(color="blue", data=subPs19, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs19, aes(x=date, y=Lumensyvyys_cm))+
  geom_line(data=agWTD19, aes(x=date, y=WTLCCm)) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+

```

```

theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
      axis.title.y.right = element_text(hjust=0.25), legend.position="top",
      axis.title.y.left=element_text(hjust=0.15)) +
scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-15, 30), breaks=seq(-15,30,5),
                    sec.axis=sec_axis(~., name="Sademäärä mm, lumensyvyys cm", breaks=seq(0,30,2)))+
geom_hline(yintercept=0, color = "black")
avgWTDps19
avgWTDps20 <- ggplot() +
  geom_col(color="blue", data=subPs20, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs20, aes(x=date, y=Lumensyvyys_cm))+
  geom_line(data=agWTD20, aes(x=date, y=WTLcmm)) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.25), legend.position="top",
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-15, 30), breaks=seq(-15,30,5),
                    sec.axis=sec_axis(~., name="Sademäärä mm, lumensyvyys cm", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
avgWTDps20
# WTD & Ps in same chart
WTDps19 <- ggplot() +
  geom_col(color="blue", data=subPs19, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs19, aes(x=date, y=Lumensyvyys_cm))+
  geom_line(data=data_WT19, aes(x=date, y=WTLcmm), size=0.3) +
  geom_point(data=data_WT19, aes(x=date, y=WTLcmm), size=1, shape=1)+
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.24), legend.position = "top",
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-15, 30), breaks=seq(-15,30,5),
                    sec.axis=sec_axis(~., name="Sademäärä mm, lumensyvyys cm", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
WTDps19
WTDps20 <- ggplot() +
  geom_col(color="blue", data=subPs20, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs20, aes(x=date, y=Lumensyvyys_cm))+
  geom_line(data=data_WT20, aes(x=date, y=WTLcmm), size=0.3) +
  geom_point(data=data_WT20, aes(x=date, y=WTLcmm), size=1, shape=1)+
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.24), legend.position = "top",
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-15, 30), breaks=seq(-15,30,5),
                    sec.axis=sec_axis(~., name="Sademäärä mm, lumensyvyys cm", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
WTDps20

```

## Liite 3. Loggerin 102 datan käsittely R-koodi data plotter 102.R

```

library(lubridate) # Date and time handling
library(dplyr) # Data handling
library(ggplot2) # Plotting package
library(patchwork) # To display 2 charts together
library(hrbrthemes) # Additional themes for ggplot2
# Set working directory
setwd("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data plotting/102")
# Read WT data
data_WT19 <- read.csv("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data
plotting/102/102_2019_treated_with_logger_installation.csv",
  header = TRUE, sep = ",", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
data_WT20 <- read.csv("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data
plotting/102/102_2020_treated_with_logger_installation.csv",
  header = TRUE, sep = ",", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
any(is.na(data_WT20$WTLCCm))
any(is.na(data_WT19$WTLCCm))
any(is.infinite(data_WT20$WTLCCm))
any(is.infinite(data_WT19$WTLCCm))
# Create a function for calculating daily average
stat <- function(x) c(mean = mean(x))
# Aggregate WTD into daily mean values into new dataset
data_WT19$WTLCCm[data_WT19$WTLCCm>1.45]<-NA # remove outliers outside logger measurement range
data_WT19$Hours <- format(as.POSIXct(data_WT19$Date.Time, "%d.%m.%Y %H:%M", tz = ""), format = "%H:%M:%S") #
Add time column
data_WT19$date <- format(as.Date(data_WT19$Date.Time, "%d.%m.%Y"), format = "%m/%d/%Y") # Add date column
data_WT20$Hours <- format(as.POSIXct(data_WT20$Date.Time, "%d.%m.%Y %H:%M", tz = ""), format = "%H:%M:%S") #
Add time column
data_WT20$date <- format(as.Date(data_WT20$Date.Time, "%d.%m.%Y"), format = "%m/%d/%Y") # Add date column
agWTD19 <- aggregate(WTLCCm ~ date, data_WT19, stat)
agWTD20 <- aggregate(WTLCCm ~ date, data_WT20, stat)
# Read precipitation grid data
data_PtG19 <- read.delim("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data plotting/102/102_logger_PT_2019_gridded.txt",
  header = TRUE, sep = "", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
data_PtG20 <- read.delim("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data plotting/102/102_logger_PT_2020_gridded.txt",
  header = TRUE, sep = "", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
# Aggregate Pout and Tout into mean values into new dataset
data_PTg19$date <- as.Date(data_PTg19$dateOut, "%d.%m.%Y")
data_PTg20$date <- as.Date(data_PTg20$dateOut, "%Y-%m-%d")
agPg19 <- aggregate(Pout ~ date, data_PTg19, stat)
agTg19 <- aggregate(Tout ~ date, data_PTg19, stat)
agPg20 <- aggregate(Pout ~ date, data_PTg20, stat)
# Create subsets for measurement season
subPg19 <- agPg19[169:245,]
subTg19 <- agTg19[183:245,]
subPg20 <- agPg20[126:287,]
# Sum of P for measurement season
sum(subPg19$Pout)
sum(subPg20$Pout)
# Avg of T for measurement season
mean(subTg19$Tout)
# Read precipitation data from closest station
data_Ps19 <- read.csv("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Utajärvi_Särkijärvi_2019.csv",
  header = TRUE, sep = ",", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
data_Ps20 <- read.csv("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Utajärvi_Särkijärvi_2020.csv",
  header = TRUE, sep = ",", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
# Aggregate sademäärä_mm into mean values into new dataset
data_Ps19$date <- as.Date(with(data_Ps19, paste(Vuosi, Kk, Pv, sep="-")), "%Y-%m-%d")
data_Ps20$date <- as.Date(with(data_Ps20, paste(Vuosi, Kk, Pv, sep="-")), "%Y-%m-%d")
agPs19 <- aggregate(Sademäärä_mm ~ date, data_Ps19, stat)
agSs19 <- aggregate(Lumensyvyys_cm ~ date, data_Ps19, stat)
agPs20 <- aggregate(Sademäärä..mm. ~ date, data_Ps20, stat)
agSs20 <- aggregate(Lumensyvyys..cm. ~ date, data_Ps20, stat)
# Replace -1 values with 0 value in agPs data
agPs19[agPs19<0]<-0
agSs19[agSs19<0]<-0
agPs20[agPs20<0]<-0
agSs20[agSs20<0]<-0

```

```

# Create a subset for time period
subPs19 <- agPs19[169:245.]
subSs19 <- agSs19[169:245.]
subSs19[subSs19==0]<-NA
subPs20 <- agPs20[126:287.]
subSs20 <- agSs20[126:287.]
subSs20[subSs20==0]<-NA
# Check data has a date format column
str(agWTD19)
agWTD19$date <- mdy(agWTD19$date)
str(agWTD20)
agWTD20$date <- mdy(agWTD20$date)
str(subPs19)
str(subPs20)
str(subSs19)
str(subSs20)
str(subPg19)
str(subPg20)
str(subTg19)
str(subTg20)
str(data_WT19)
data_WT19$date <- mdy(data_WT19$date)
str(data_WT20)
data_WT20$date <- mdy(data_WT20$date)
# ----- WTD statistical analysis -----
# Min, max, mean, median, sd 2019
maxWTD19 <- max(data_WT19$WTLCcm, na.rm=TRUE)
maxWTD19
minWTD19 <- min(data_WT19$WTLCcm, na.rm=TRUE)
minWTD19
meanWTD19 <- mean(data_WT19$WTLCcm, na.rm=TRUE)
meanWTD19
medianWTD19 <- median(data_WT19$WTLCcm, na.rm=TRUE)
medianWTD19
sdWTD19 <- sd(data_WT19$WTLCcm, na.rm=TRUE)
sdWTD19
# Min, max, mean, median, sd 2020
maxWTD20 <- max(data_WT20$WTLCcm)
maxWTD20
minWTD20 <- min(data_WT20$WTLCcm)
minWTD20
meanWTD20 <- mean(data_WT20$WTLCcm)
meanWTD20
medianWTD20 <- median(data_WT20$WTLCcm)
medianWTD20
sdWTD20 <- sd(data_WT20$WTLCcm)
sdWTD20
# Check if WT data follows natural distribution
hist(data_WT19$WTLCcm)
hist(data_WT20$WTLCcm)
# 2019
vect<-data_WT19$WTLCcm
vect<-vect[complete.cases(vect)]
sum(0<vect)/length(vect)*100
(length(vect[vect > -20]) - length(vect[vect > 0]))/length(vect)*100 # % of time between 0...-20cm
sum(-20>vect)/length(vect)*100 # % of time below -20cm
# 2020
vect<-data_WT20$WTLCcm
sum(0<vect)/length(vect)*100 # % of time above ground (WTD>0cm)
(length(vect[vect > -20]) - length(vect[vect > 0]))/length(vect)*100 # % of time between 0...-20cm
sum(-20>vect)/length(vect)*100 # % of time below -20cm
# ----- PLOTTING -----
# Average WTD
# Lineplot average WTD agWTD
avgWTD19 <- ggplot(agWTD19, aes(x=date, y=WTLCcm)) +
  geom_line() +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous( limits=c(-20, 10), breaks=seq(-20,10,5))+
  geom_hline(yintercept=0, linetype="dashed", color = "black")
avgWTD19
avgWTD20 <- ggplot(agWTD20, aes(x=date, y=WTLCcm)) +
  geom_line() +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous( limits=c(-25, 10), breaks=seq(-25,10,5))+
  geom_hline(yintercept=0, linetype="dashed", color = "black")

```

```

avgWTD20
# Boxplot average WTD agWTD
avgWTDbox19 <- ggplot(agWTD19, aes(y=WTLCCm)) +
  geom_boxplot(outlier.colour="black", outlier.shape=1,
    outlier.size=2, notch=FALSE)+
  theme_classic()+
  theme(axis.ticks.x = element_blank(), axis.text.x = element_blank()) +
  scale_y_continuous(name="WTD päiväkohtainen keskiarvo cm", limits=c(-20, 10), breaks=seq(-20,10,5))
avgWTDbox19
avgWTDbox20 <- ggplot(agWTD20, aes(y=WTLCCm)) +
  geom_boxplot(outlier.colour="black", outlier.shape=1,
    outlier.size=2, notch=FALSE)+
  theme_classic()+
  theme(axis.ticks.x = element_blank(), axis.text.x = element_blank()) +
  scale_y_continuous(name="WTD päiväkohtainen keskiarvo cm", limits=c(-25, 10), breaks=seq(-25,10,5))
avgWTDbox20
# Boxplot and lineplot side by side
avgWTDbox19+avgWTD19+plot_layout(widths = c(0.5, 5))
avgWTDbox20+avgWTD20+plot_layout(widths = c(0.5, 5))
# Full WTD dataset
# Lineplot full WTD dataset
fullWTD19 <- ggplot(data_WT19, aes(x=date, y=WTLCCm)) +
  geom_point(size=1, shape=1)+
  geom_line(size=0.4) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-20, 10), breaks=seq(-20,10,5))+
  geom_hline(yintercept=0, linetype="dashed", color = "black")
fullWTD19
fullWTD20 <- ggplot(data_WT20, aes(x=date, y=WTLCCm)) +
  geom_point(size=1, shape=1)+
  geom_line(size=0.4) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-25, 10), breaks=seq(-25,10,5))+
  geom_hline(yintercept=0, linetype="dashed", color = "black")
fullWTD20
# Boxplot full WTD dataset
fullWTDbox19 <- ggplot(data_WT19, aes(y=WTLCCm)) +
  geom_boxplot(outlier.colour="black", outlier.shape=1,
    outlier.size=2, notch=FALSE)+
  theme_classic()+
  theme(axis.ticks.x = element_blank(), axis.text.x = element_blank()) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-20, 10), breaks=seq(-20,10,5))
fullWTDbox19
fullWTDbox20 <- ggplot(data_WT20, aes(y=WTLCCm)) +
  geom_boxplot(outlier.colour="black", outlier.shape=1,
    outlier.size=2, notch=FALSE)+
  theme_classic()+
  theme(axis.ticks.x = element_blank(), axis.text.x = element_blank()) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-25, 10), breaks=seq(-25,10,5))
fullWTDbox20
# Boxplot and lineplot side by side
fullWTDbox19+fullWTD19+plot_layout(widths = c(0.5, 5))
fullWTDbox20+fullWTD20+plot_layout(widths = c(0.5, 5))
# Air temperature from grid Tg
# Plot air temperature from grid subTg
Tg19 <- ggplot(subTg19, aes(x=date, y=Tout)) +
  geom_line() +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Ilman lämpötila degC", limits=c(-5, 25), breaks=seq(-5,25,5))
Tg19
# Precipitation from grid Pg
# Column plot precipitation from grid Pg
Pg19 <- ggplot(subPg19, aes(x=date, y=Pout)) +
  geom_col() +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d")+
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Sademäärä mm", limits=c(-0, 30), breaks=seq(0,30,2))
Pg19
Pg20 <- ggplot(subPg20, aes(x=date, y=Pout)) +
  geom_col() +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d")+
  theme_classic()+

```

```

theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
scale_y_continuous(name="Sademäärä mm", limits=c(-0, 30), breaks=seq(0,30,2))
Pg20
# Avg WTD, Tg & Pg in same chart
WTDavgPg19 <- ggplot() +
  geom_col(color="blue", data=subPg19, aes(x=date, y=Pout)) +
  geom_line(data=agWTD19, aes(x=date, y=WTLCCm)) +
  geom_line(data=subTg19, aes(x=date, y=Tout), linetype="dashed") +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(legend.position="top", axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.24),
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-20, 30), breaks=seq(-20,30,5),
        sec.axis=sec_axis(~., name="Sademäärä mm, ilman lämpötila degC", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
WTDavgPg19
WTDavgPg20 <- ggplot() +
  geom_col(color="blue", data=subPg20, aes(x=date, y=Pout)) +
  geom_line(data=agWTD20, aes(x=date, y=WTLCCm)) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(legend.position="top", axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.24),
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-25, 30), breaks=seq(-25,30,5),
        sec.axis=sec_axis(~., name="Sademäärä mm", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
WTDavgPg20
# WTD, Tg & Pg in same chart
WTDPg19 <- ggplot() +
  geom_col(color="blue", data=subPg19, aes(x=date, y=Pout)) +
  geom_line(data=data_WT19, aes(x=date, y=WTLCCm), size=0.3) +
  geom_point(data=data_WT19, aes(x=date, y=WTLCCm), size=1, shape=1)+
  geom_line(linetype="dashed", data=subTg19, aes(x=date, y=Tout)) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.24), legend.position="top",
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-20, 30), breaks=seq(-20,30,5),
        sec.axis=sec_axis(~., name="Sademäärä mm, ilman lämpötila degC", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
WTDPg19
WTDPg20 <- ggplot() +
  geom_col(color="blue", data=subPg20, aes(x=date, y=Pout)) +
  geom_line(data=data_WT20, aes(x=date, y=WTLCCm), size=0.3) +
  geom_point(data=data_WT20, aes(x=date, y=WTLCCm), size=1, shape=1)+
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.24), legend.position="top",
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-25, 30), breaks=seq(-25,30,5),
        sec.axis=sec_axis(~., name="Sademäärä mm", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
WTDPg20
# Precipitation from closest station Ps
# Column plot precipitation from closest station subPs
Ps19 <- ggplot() +
  geom_col(color="blue", data=subPs19, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs19, aes(x=date, y=Lumensyvyys_cm))+
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d")+
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Sademäärä mm, lumensyvyys cm", limits=c(-0, 30), breaks=seq(0,30,2))
Ps19
Ps20 <- ggplot() +
  geom_col(color="blue", data=subPs20, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs20, aes(x=date, y=Lumensyvyys_cm))+
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d")+
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Sademäärä mm, lumensyvyys cm", limits=c(-0, 30), breaks=seq(0,30,2))
Ps20
# Avg WTD & Ps in same chart
avgWTDPs9 <- ggplot() +
  geom_col(color="blue", data=subPs19, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs19, aes(x=date, y=Lumensyvyys_cm))+

```



```

geom_line(data=agWTD19, aes(x=date, y=WTLCcm)) +
scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
theme_classic()+
theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
      axis.title.y.right = element_text(hjust=0.25), legend.position="top",
      axis.title.y.left=element_text(hjust=0.15)) +
scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-20, 30), breaks=seq(-20,30,5),
                   sec.axis=sec_axis(~., name="Sademäärä mm, lumensyvyys cm", breaks=seq(0,30,2)))+
geom_hline(yintercept=0, color = "black")
avgWTDPs19
avgWTDPs20 <- ggplot() +
  geom_col(color="blue", data=subPs20, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs20, aes(x=date, y=Lumensyvyys_cm))+
  geom_line(data=agWTD20, aes(x=date, y=WTLCcm)) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.25), legend.position="top",
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-25, 30), breaks=seq(-25,30,5),
                     sec.axis=sec_axis(~., name="Sademäärä mm, lumensyvyys cm", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
avgWTDPs20
# WTD & Ps in same chart
WTDPs19 <- ggplot() +
  geom_col(color="blue", data=subPs19, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs19, aes(x=date, y=Lumensyvyys_cm))+
  geom_line(data=data_WT19, aes(x=date, y=WTLCcm), size=0.3) +
  geom_point(data=data_WT19, aes(x=date, y=WTLCcm), size=1, shape=1)+
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.24), legend.position = "top",
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-20, 30), breaks=seq(-20,30,5),
                     sec.axis=sec_axis(~., name="Sademäärä mm, lumensyvyys cm", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
WTDPs19
WTDPs20 <- ggplot() +
  geom_col(color="blue", data=subPs20, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs20, aes(x=date, y=Lumensyvyys_cm))+
  geom_line(data=data_WT20, aes(x=date, y=WTLCcm), size=0.3) +
  geom_point(data=data_WT20, aes(x=date, y=WTLCcm), size=1, shape=1)+
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.24), legend.position = "top",
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-25, 30), breaks=seq(-25,30,5),
                     sec.axis=sec_axis(~., name="Sademäärä mm, lumensyvyys cm", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
WTDPs20

```

## Liite 4. Loggerin 103 datan käsittelyn R-koodi data plotter 103.R

```

library(lubridate) # Date and time handling
library(dplyr) # Data handling
library(ggplot2) # Plotting package
library(patchwork) # To display 2 charts together
library(hrbrthemes) # Additional themes for ggplot2
# Set working directory
setwd("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data plotting/103")
# Read WT data
data_WT19 <- read.csv("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data
plotting/103/103_2019_treated_with_logger_installation.csv",
  header = TRUE, sep = ",", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
data_WT20 <- read.csv("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data
plotting/103/103_2020_treated_with_logger_installation.csv",
  header = TRUE, sep = ",", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
any(is.na(data_WT20$WTLCCm))
any(is.na(data_WT19$WTLCCm))
any(is.infinite(data_WT20$WTLCCm))
any(is.infinite(data_WT19$WTLCCm))
# Create a function for calculating daily average
stat <- function(x) c(mean = mean(x))
# Aggregate WTD into daily mean values into new dataset
data_WT19$WTLCCm[data_WT19$WTLCCm>-4.6]<-NA # remove outliers outside logger measurement range
data_WT19$Hours <- format(as.POSIXct(data_WT19$Date.Time, "%d.%m.%Y %H:%M", tz = ""), format = "%H:%M:%S") #
Add time column
data_WT19$date <- format(as.Date(data_WT19$Date.Time, "%d.%m.%Y"), format = "%m/%d/%Y") # Add date column
data_WT20$Hours <- format(as.POSIXct(data_WT20$Date.Time, "%d.%m.%Y %H:%M", tz = ""), format = "%H:%M:%S") #
Add time column
data_WT20$date <- format(as.Date(data_WT20$Date.Time, "%d.%m.%Y"), format = "%m/%d/%Y") # Add date column
agWTD19 <- aggregate(WTLCCm ~ date, data_WT19, stat, na.action=NULL)
agWTD20 <- aggregate(WTLCCm ~ date, data_WT20, stat, na.action=NULL)
# Read precipitation grid data
data_PtG19 <- read.delim("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data plotting/103/103_logger_PT_2019_gridded.txt",
  header = TRUE, sep = "", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
data_PtG20 <- read.delim("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data plotting/103/103_logger_PT_2020_gridded.txt",
  header = TRUE, sep = "", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
# Aggregate Pout and Tout into into mean values into new dataset
data_PtG19$date <- as.Date(data_PtG19$dateOut, "%d.%m.%Y")
data_PtG20$date <- as.Date(data_PtG20$dateOut, "%Y-%m-%d")
agPg19 <- aggregate(Pout ~ date, data_PtG19, stat)
agTg19 <- aggregate(Tout ~ date, data_PtG19, stat)
agPg20 <- aggregate(Pout ~ date, data_PtG20, stat)
# Create subsets for measurement season
subPg19 <- agPg19[169:272,]
subTg19 <- agTg19[183:272,]
subPg20 <- agPg20[126:287,]
# Sum of P for measurement season
sum(subPg19$Pout)
sum(subPg20$Pout)
# Avg of T for measurement season
mean(subTg19$Tout)
# Read precipitation data from closest station
data_Ps19 <- read.csv("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Utajärvi_Särkijärvi_2019.csv",
  header = TRUE, sep = ",", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
data_Ps20 <- read.csv("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Utajärvi_Särkijärvi_2020.csv",
  header = TRUE, sep = ",", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
# Aggregate sademäärä_mm into into mean values into new dataset
data_Ps19$date <- as.Date(with(data_Ps19, paste(Vuosi, Kk, Pv, sep="-")), "%Y-%m-%d")
data_Ps20$date <- as.Date(with(data_Ps20, paste(Vuosi, Kk, Pv, sep="-")), "%Y-%m-%d")
agPs19 <- aggregate(Sademäärä_mm ~ date, data_Ps19, stat)
agSs19 <- aggregate(Lumensyvyys_cm ~ date, data_Ps19, stat)
agPs20 <- aggregate(Sademäärä..mm. ~ date, data_Ps20, stat)
agSs20 <- aggregate(Lumensyvyys..cm. ~ date, data_Ps20, stat)
# Replace -1 values with 0 value in agPs data
agPs19[agPs19<0]<-0
agSs19[agSs19<0]<-0
agPs20[agPs20<0]<-0
agSs20[agSs20<0]<-0
# Create a subset for time period

```

```

subPs19 <- agPs19[169:272,]
subSs19 <- agSs19[169:272,]
subSs[subSs==0]<-NA
subPs20 <- agPs20[126:287,]
subSs20 <- agSs20[126:287,]
subSs20[subSs20==0]<-NA
# Check data has a date format column
str(agWTD19)
agWTD19$date <- mdy(agWTD19$date)
str(agWTD20)
agWTD20$date <- mdy(agWTD20$date)
str(subPs19)
str(subPs20)
str(subSs19)
str(subSs20)
str(subPg19)
str(subPg20)
str(subTg19)
str(subTg20)
str(data_WT19)
data_WT19$date <- mdy(data_WT19$date)
str(data_WT20)
data_WT20$date <- mdy(data_WT20$date)
# ----- WTD statistical analysis -----
# min, max, mean, median, sd 2019
maxWTD19 <- max(data_WT19$WTLCCm, na.rm=TRUE)
maxWTD19
minWTD19 <- min(data_WT19$WTLCCm, na.rm=TRUE)
minWTD19
meanWTD19 <- mean(data_WT19$WTLCCm, na.rm=TRUE)
meanWTD19
medianWTD19 <- median(data_WT19$WTLCCm, na.rm=TRUE)
medianWTD19
sdWTD19 <- sd(data_WT19$WTLCCm, na.rm=TRUE)
sdWTD19
# min, max, mean, median, sd 2020
maxWTD20 <- max(data_WT20$WTLCCm)
maxWTD20
minWTD20 <- min(data_WT20$WTLCCm)
minWTD20
meanWTD20 <- mean(data_WT20$WTLCCm)
meanWTD20
medianWTD20 <- median(data_WT20$WTLCCm)
medianWTD20
sdWTD20 <- sd(data_WT20$WTLCCm)
sdWTD20
# Check if WT data follows natural distribution
hist(data_WT19$WTLCCm)
hist(data_WT20$WTLCCm)
# Mann-Whitney U-test for 2020 and 2019 data
wilcox.test(data_WT19$WTLCCm, data_WT20$WTLCCm,
             alternative = "less",
             mu = 0, paired = FALSE, exact = TRUE, correct = TRUE,
             conf.int = TRUE, conf.level = 0.95)
# Read 101 WT data
data_10119 <- read.csv('/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data
plotting/101/101_2019_treated_with_logger_installation.csv',
                    header = TRUE, sep = ";", quote = "",
                    dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
data_10120 <- read.csv('/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data
plotting/101/101_2020_treated_with_logger_installation.csv',
                    header = TRUE, sep = ";", quote = "",
                    dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
# Aggregate 101 WTD into daily mean values into new dataset
data_10119$Hours <- format(as.POSIXct(data_10119$Date.Time, "%d.%m.%Y %H:%M", tz = ""), format = "%H:%M:%S") #
Add time column
data_10119$date <- format(as.Date(data_10119$Date.Time, "%d.%m.%Y"), format = "%m/%d/%Y") # Add date column
data_10120$Hours <- format(as.POSIXct(data_10120$Date.Time, "%d.%m.%Y %H:%M", tz = ""), format = "%H:%M:%S") #
Add time column
data_10120$date <- format(as.Date(data_10120$Date.Time, "%d.%m.%Y"), format = "%m/%d/%Y") # Add date column
agWTD10119 <- aggregate(WTLCCm ~ date, data_10119, stat)
agWTD10120 <- aggregate(WTLCCm ~ date, data_10120, stat)
str(agWTD10119)
agWTD10119$date <- mdy(agWTD10119$date)
str(agWTD10120)
agWTD10120$date <- mdy(agWTD10120$date)
# Mann-Whitney U-test for 101 vs 103 2019
hist(data_10119$WTLCCm)
hist(data_WT19$WTLCCm)

```

```

wilcox.test(data_10119$WTLcCm, data_WT19$WTLcCm,
            alternative = "greater",
            mu = 0, paired = FALSE, exact = TRUE, correct = TRUE,
            conf.int = TRUE, conf.level = 0.95)
# Mann-Whitney U-test for 101 vs 103 2020
hist(data_10120$WTLcCm)
hist(data_WT20$WTLcCm)
wilcox.test(data_10120$WTLcCm, data_WT20$WTLcCm,
            alternative = "two.sided",
            mu = 0, paired = FALSE, exact = TRUE, correct = TRUE,
            conf.int = TRUE, conf.level = 0.95)
wilcox.test(data_10120$WTLcCm, data_WT20$WTLcCm,
            alternative = "less",
            mu = 0, paired = FALSE, exact = TRUE, correct = TRUE,
            conf.int = TRUE, conf.level = 0.95)
# 2019
vect<-data_WT19$WTLcCm
vect<-vect[complete.cases(vect)]
sum(0<vect)/length(vect)*100 # % of time above ground (WTD>0cm)
(length(vect[vect > -20]) - length(vect[vect > 0]))/length(vect)*100 # % of time between 0...-20cm
sum(-20>vect)/length(vect)*100 # % of time below -20cm
# 2020
vect<-data_WT20$WTLcCm
sum(0<vect)/length(vect)*100 # % of time above ground (WTD>0cm)
(length(vect[vect > -20]) - length(vect[vect > 0]))/length(vect)*100 # % of time between 0...-20cm
sum(-20>vect)/length(vect)*100 # % of time below -20cm
# Read and check 104 WT data
data_10419 <- read.csv('/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data
plotting/104/104_2019_treated_with_logger_installation.csv',
                    header = TRUE, sep = ";", quote = "",
                    dec = ",", fill = TRUE, comment.char = "", skipNul=FALSE)
data_10420 <- read.csv('/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data
plotting/104/104_2020_treated_with_logger_installation.csv',
                    header = TRUE, sep = ";", quote = "",
                    dec = ",", fill = TRUE, comment.char = "", skipNul=FALSE)
any(is.na(data_10420$WTLcCm))
any(is.na(data_10419$WTLcCm))
any(is.infinite(data_10420$WTLcCm))
any(is.infinite(data_10419$WTLcCm))
# Aggregate WTD into daily mean values into new dataset
data_10419$WTLcCm[data_10419$WTLcCm>-10]<-NA # remove outliers outside logger measurement range
data_10419$Hours <- format(as.POSIXct(data_10419$Date.Time, "%d.%m.%Y %H:%M", tz = ""), format = "%H:%M:%S") #Add
time column
data_10419$date <- format(as.Date(data_10419$Date.Time, "%d.%m.%Y"), format = "%m/%d/%Y") # Add date column
data_10420$Hours <- format(as.POSIXct(data_10420$Date.Time, "%d.%m.%Y %H:%M", tz = ""), format = "%H:%M:%S") #Add
time column
data_10420$date <- format(as.Date(data_10420$Date.Time, "%d.%m.%Y"), format = "%m/%d/%Y") # Add date column
# Combined 103 and 104 statistical values
WTDall19<- c(as.vector(data_10419[,2]), as.vector(data_WT19[,2]))
WTDall19<- WTDall19[!is.na(WTDall19)]
any(is.na(WTDall19))
WTDall20<- c(as.vector(data_10420[,2]), as.vector(data_WT20[,2]))
WTDall20<- WTDall20[!is.na(WTDall20)]
any(is.na(WTDall20))
# max, min, mean, median, sd 2019
mean(WTDall19)
median(WTDall19)
max(WTDall19)
min(WTDall19)
# min, max, mean, median, sd 2020
mean(WTDall20)
median(WTDall20)
max(WTDall20)
min(WTDall20)
# ----- PLOTTING -----
# Average WTD
# Lineplot average WTD agWTD
avgWTD19 <- ggplot(agWTD19, aes(x=date, y=WTLcCm)) +
  geom_line() +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous( limits=c(-45, 10), breaks=seq(-45,20,5))+
  geom_hline(yintercept=0, linetype="dashed", color = "black")
avgWTD19
avgWTD20 <- ggplot(agWTD20, aes(x=date, y=WTLcCm)) +
  geom_line() +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+

```

```

theme(axis.title = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
scale_y_continuous( limits=c(-10, 15), breaks=seq(-10,15,5))+
geom_hline(yintercept=0, linetype="dashed", color = "black")
avgWTD20
# Boxplot average WTD agWTD
avgWTDbox19 <- ggplot(agWTD19, aes(y=WTLCCm)) +
  geom_boxplot(outlier.colour="black", outlier.shape=1,
    outlier.size=2, notch=FALSE)+
  theme_classic()+
  theme(axis.ticks.x = element_blank(), axis.text.x = element_blank()) +
  scale_y_continuous(name="WTD päivakohtainen keskiarvo cm", limits=c(-45, 10), breaks=seq(-45,10,5))
avgWTDbox19
avgWTDbox20 <- ggplot(agWTD20, aes(y=WTLCCm)) +
  geom_boxplot(outlier.colour="black", outlier.shape=1,
    outlier.size=2, notch=FALSE)+
  theme_classic()+
  theme(axis.ticks.x = element_blank(), axis.text.x = element_blank()) +
  scale_y_continuous(name="WTD päivakohtainen keskiarvo cm", limits=c(-10, 15), breaks=seq(-10,15,5))
avgWTDbox20
# Boxplot and lineplot side by side
avgWTDbox19+avgWTD19+plot_layout(widths = c(0.5, 5))
avgWTDbox20+avgWTD20+plot_layout(widths = c(0.5, 5))
# Full WTD dataset
# Lineplot full WTD dataset
fullWTD19 <- ggplot(data_WT19, aes(x=date, y=WTLCCm)) +
  geom_point(size=1, shape=1)+
  geom_line(size=0.4) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-45, 10), breaks=seq(-45,10,5))+
  geom_hline(yintercept=0, linetype="dashed", color = "black")
fullWTD19
fullWTD20 <- ggplot(data_WT20, aes(x=date, y=WTLCCm)) +
  geom_point(size=1, shape=1)+
  geom_line(size=0.4) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-10, 15), breaks=seq(-10,15,5))+
  geom_hline(yintercept=0, linetype="dashed", color = "black")
fullWTD20
# Boxplot full WTD dataset
fullWTDbox19 <- ggplot(data_WT19, aes(y=WTLCCm)) +
  geom_boxplot(outlier.colour="black", outlier.shape=1,
    outlier.size=2, notch=FALSE)+
  theme_classic()+
  theme(axis.ticks.x = element_blank(), axis.text.x = element_blank()) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-45, 10), breaks=seq(-45,10,5))
fullWTDbox19
fullWTDbox20 <- ggplot(data_WT20, aes(y=WTLCCm)) +
  geom_boxplot(outlier.colour="black", outlier.shape=1,
    outlier.size=2, notch=FALSE)+
  theme_classic()+
  theme(axis.ticks.x = element_blank(), axis.text.x = element_blank()) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-10, 15), breaks=seq(-10,15,5))
fullWTDbox20
# Boxplot and lineplot side by side
fullWTDbox19+fullWTD19+plot_layout(widths = c(0.5, 5))
fullWTDbox20+fullWTD20+plot_layout(widths = c(0.5, 5))
# Air temperature from grid Tg
# Plot air temperature from grid subTg
Tg19 <- ggplot(subTg19, aes(x=date, y=Tout)) +
  geom_line() +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Ilman lämpötila degC", limits=c(-5, 25), breaks=seq(-5,25,5))
Tg19
# Precipitation from grid Pg
# Column plot precipitation from grid Pg
Pg19 <- ggplot(subPg19, aes(x=date, y=Pout)) +
  geom_col() +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Sademäärä mm", limits=c(-0, 30), breaks=seq(0,30,2))
Pg19
Pg20 <- ggplot(subPg20, aes(x=date, y=Pout)) +

```

```

geom_col() +
scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
theme_classic() +
theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
scale_y_continuous(name="Sademäärä mm", limits=c(-0, 30), breaks=seq(0,30,2))
Pg20
# Avg WTD, Tg & Pg in same chart
WTDavgPg19 <- ggplot() +
  geom_col(color="blue", data=subPg19, aes(x=date, y=Pout, fill="P", color="")) +
  geom_line(data=agWTD19, aes(x=date, y=WTLCCm, color="WTD")) +
  geom_line(data=subTg19, aes(x=date, y=Tout, color="T")) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic() +
  theme(legend.position="top", axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0), legend.title = element_blank(),
        axis.title.y.left=element_text(hjust=0.15), legend.key = element_blank()) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-45, 30), breaks=seq(-45,30,5),
                    sec.axis=sec_axis(~., name="Sademäärä mm, ilman lämpötila degC", breaks=seq(0,30,2))) +
  scale_color_manual("", values = c( "WTD" = "orange",
                                     "T"="red", "P"="dodgerblue3")) +
  scale_fill_manual("", values= c("P"="dodgerblue")) +
  geom_hline(yintercept=0, color = "black")
WTDavgPg20
WTDavgPg20 <- ggplot() +
  geom_col(color="blue", data=subPg20, aes(x=date, y=Pout, fill="P", color="")) +
  geom_line(data=agWTD20, aes(x=date, y=WTLCCm, color="WTD")) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic() +
  theme(legend.position="top", axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0), legend.title = element_blank(),
        axis.title.y.left=element_text(hjust=0.15), legend.key = element_blank()) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-15, 30), breaks=seq(-15,30,5),
                    sec.axis=sec_axis(~., name="Sademäärä mm", breaks=seq(0,30,2))) +
  scale_color_manual(values = c( "WTD" = "orange", "P"="dodgerblue3")) +
  scale_fill_manual("", values= c("P"="dodgerblue")) +
  geom_hline(yintercept=0, color = "black")
WTDavgPg20
# WTD, Tg & Pg in same chart
WTDPg19 <- ggplot() +
  geom_col(color="blue", data=subPg19, aes(x=date, y=Pout)) +
  geom_line(data=data_WT19, aes(x=date, y=WTLCCm), size=0.3) +
  geom_point(data=data_WT19, aes(x=date, y=WTLCCm), size=1, shape=1) +
  geom_line(linetype="dashed", data=subTg19, aes(x=date, y=Tout)) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic() +
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.24), legend.position="top",
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-45, 30), breaks=seq(-45,30,5),
                    sec.axis=sec_axis(~., name="Sademäärä mm, ilman lämpötila degC", breaks=seq(0,30,2))) +
  geom_hline(yintercept=0, color = "black")
WTDPg19
WTDPg20 <- ggplot() +
  geom_col(color="blue", data=subPg20, aes(x=date, y=Pout)) +
  geom_line(data=data_WT20, aes(x=date, y=WTLCCm), size=0.3) +
  geom_point(data=data_WT20, aes(x=date, y=WTLCCm), size=1, shape=1) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic() +
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.24), legend.position="top",
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-15, 30), breaks=seq(-15,30,5),
                    sec.axis=sec_axis(~., name="Sademäärä mm", breaks=seq(0,30,2))) +
  geom_hline(yintercept=0, color = "black")
WTDPg20
# Precipitation from closest station Ps
# Column plot precipitation from closest station subPs
Ps19 <- ggplot() +
  geom_col(color="blue", data=subPs19, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs19, aes(x=date, y=Lumensyvyys_cm)) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic() +
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Sademäärä mm, lumensyvyys cm", limits=c(-0, 30), breaks=seq(0,30,2))
Ps19
Ps20 <- ggplot() +
  geom_col(color="blue", data=subPs20, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs20, aes(x=date, y=Lumensyvyys_cm)) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +

```

```

theme_classic()+
theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
scale_y_continuous(name="Sademäärä mm, lumensyvyys cm", limits=c(-0, 30), breaks=seq(0,30,2))
Ps20
# Avg WTD & Ps in same chart
avgWTDPs9 <- ggplot() +
  geom_col(color="blue", data=subPs19, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs19, aes(x=date, y=Lumensyvyys_cm))+
  geom_line(data=agWTD19, aes(x=date, y=WTLCCm)) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.25), legend.position="top",
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-45, 30), breaks=seq(-45,30,5),
        sec.axis=sec_axis(~., name="Sademäärä mm, lumensyvyys cm", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
avgWTDPs19
avgWTDPs20 <- ggplot() +
  geom_col(color="blue", data=subPs20, aes(x=date, y=Sademäärä..mm.)) +
  geom_line(data=agWTD20, aes(x=date, y=WTLCCm)) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.25), legend.position="top",
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-15, 30), breaks=seq(-15,30,5),
        sec.axis=sec_axis(~., name="Sademäärä mm, lumensyvyys cm", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
avgWTDPs20
# WTD & Ps in same chart
WTDPs19 <- ggplot() +
  geom_col(color="blue", data=subPs19, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs19, aes(x=date, y=Lumensyvyys_cm))+
  geom_line(data=data_WT19, aes(x=date, y=WTLCCm), size=0.3) +
  geom_point(data=data_WT19, aes(x=date, y=WTLCCm), size=1, shape=1)+
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.24), legend.position = "top",
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-45, 30), breaks=seq(-45,30,5),
        sec.axis=sec_axis(~., name="Sademäärä mm, lumensyvyys cm", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
WTDPs19
WTDPs20 <- ggplot() +
  geom_col(color="blue", data=subPs20, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs20, aes(x=date, y=Lumensyvyys_cm))+
  geom_line(data=data_WT20, aes(x=date, y=WTLCCm), size=0.3) +
  geom_point(data=data_WT20, aes(x=date, y=WTLCCm), size=1, shape=1)+
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.24), legend.position = "top",
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-15, 30), breaks=seq(-15,30,5),
        sec.axis=sec_axis(~., name="Sademäärä mm, lumensyvyys cm", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
WTDPs20
# Daily average WTD at 101 and 103 at same graph for the whole study period
colors<-c("101"="black", "103"="blue")
avgWTDall <- ggplot() +
  geom_line(data=agWTD19, aes(x=date, y=WTLCCm, color="103")) +
  geom_line(data=agWTD20, aes(x=date, y=WTLCCm, color="103")) +
  geom_line(data=agWTD10119, aes(x=date, y=WTLCCm, color="101")) +
  geom_line(data=agWTD10120, aes(x=date, y=WTLCCm, color="101")) +
  scale_x_date(date_breaks = "1 month", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title = element_blank(), legend.title=element_blank(),
        legend.position="top", axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous( limits=c(-45, 10), breaks=seq(-45,20,5)) +
  geom_hline(yintercept=0, linetype="dashed", color = "black") +
  scale_color_manual(values = colors)
avgWTDall

```

## Liite 5. Loggerin 104 datan käsittelyn R-koodi data plotter 104.R

```

library(lubridate) # Date and time handling
library(dplyr) # Data handling
library(ggplot2) # Plotting package
library(patchwork) # To display 2 charts together
library(hrbrthemes) # Additional themes for ggplot2
# Set working directory
setwd("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data plotting/104")
# Read and check WT data
data_WT19 <- read.csv("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data
plotting/104/104_2019_treated_with_logger_installation.csv",
  header = TRUE, sep = ",", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
data_WT20 <- read.csv("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data
plotting/104/104_2020_treated_with_logger_installation.csv",
  header = TRUE, sep = ",", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
any(is.na(data_WT20$WTLCCm))
any(is.na(data_WT19$WTLCCm))
any(is.infinite(data_WT20$WTLCCm))
any(is.infinite(data_WT19$WTLCCm))
# Create a function for calculating daily average
stat <- function(x) c(mean = mean(x))
# Aggregate WTD into daily mean values into new dataset
data_WT19$WTLCCm[data_WT19$WTLCCm>-10]<-NA # remove outliers outside logger measurement range
data_WT19$Date <- format(as.POSIXct(data_WT19$Date.Time, "%d.%m.%Y %H:%M", tz = ""), format = "%H:%M:%S")
# Add time column
data_WT19$date <- format(as.Date(data_WT19$Date.Time, "%d.%m.%Y"), format = "%m/%d/%Y") # Add date column
data_WT20$Hours <- format(as.POSIXct(data_WT20$Date.Time, "%d.%m.%Y %H:%M", tz = ""), format = "%H:%M:%S")
# Add time column
data_WT20$date <- format(as.Date(data_WT20$Date.Time, "%d.%m.%Y"), format = "%m/%d/%Y") # Add date column
agWTD19 <- aggregate(WTLCCm ~ date, data_WT19, stat, na.action=NULL)
agWTD20 <- aggregate(WTLCCm ~ date, data_WT20, stat, na.action=NULL)
# Read precipitation grid data
data_PtG19 <- read.delim("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data plotting/104/104_logger_PT_2019_gridded.txt",
  header = TRUE, sep = "", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
data_PtG20 <- read.delim("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data plotting/104/104_logger_PT_2020_gridded.txt",
  header = TRUE, sep = "", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
# Aggregate Pout and Tout into mean values into new dataset
data_PtG19$date <- as.Date(data_PtG19$dateOut, "%d.%m.%Y")
data_PtG20$date <- as.Date(data_PtG20$dateOut, "%Y-%m-%d")
agPg19 <- aggregate(Pout ~ date, data_PtG19, stat, na.action=NULL)
agTg19 <- aggregate(Tout ~ date, data_PtG19, stat, na.action=NULL)
agPg20 <- aggregate(Pout ~ date, data_PtG20, stat, na.action=NULL)
# Create subsets for measurement season
subPg19 <- agPg19[169:282,]
subTg19 <- agTg19[183:282,]
subPg20 <- agPg20[126:287,]
# Sum of P for measurement season
sum(subPg19$Pout)
sum(subPg20$Pout)
# Avg of T for measurement season
mean(subTg19$Tout)
# Read precipitation data from closest station
data_Ps19 <- read.csv("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Utajärvi_Särkijärvi_2019.csv",
  header = TRUE, sep = ",", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
data_Ps20 <- read.csv("/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Utajärvi_Särkijärvi_2020.csv",
  header = TRUE, sep = ",", quote = "",
  dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
# Aggregate sademäärä_mm into mean values into new dataset
data_Ps19$date <- as.Date(with(data_Ps19, paste(Vuosi, Kk, Pv, sep="-")), "%Y-%m-%d")
data_Ps20$date <- as.Date(with(data_Ps20, paste(Vuosi, Kk, Pv, sep="-")), "%Y-%m-%d")
agPs19 <- aggregate(Sademäärä_mm ~ date, data_Ps19, stat)
agSs19 <- aggregate(Lumensyvyys_cm ~ date, data_Ps19, stat)
agPs20 <- aggregate(Sademäärä_mm ~ date, data_Ps20, stat)
agSs20 <- aggregate(Lumensyvyys_cm ~ date, data_Ps20, stat)
# Replace -1 values with 0 value in agPs data
agPs19[agPs19<0]<-0
agSs19[agSs19<0]<-0
agPs20[agPs20<0]<-0
agSs20[agSs20<0]<-0
# Create a subset for time period

```



```

subPs19 <- agPs19[169:282,]
subSs19 <- agSs19[169:282,]
subSs19[subSs19==0]<-NA
subPs20 <- agPs20[126:287,]
subSs20 <- agSs20[126:287,]
subSs20[subSs20==0]<-NA
# Check data has a date format column
str(agWTD19)
agWTD19$date <- mdy(agWTD19$date)
str(agWTD20)
agWTD20$date <- mdy(agWTD20$date)
str(subPs19)
str(subPs20)
str(subSs19)
str(subSs20)
str(subPg19)
str(subPg20)
str(subTg19)
str(subTg20)
str(data_WT19)
data_WT19$date <- mdy(data_WT19$date)
str(data_WT20)
data_WT20$date <- mdy(data_WT20$date)
# ----- WTD statistical analysis -----
# min, max, mean, median, sd 2019
maxWTD19 <- max(data_WT19$WTLCCm, na.rm=TRUE)
maxWTD19
minWTD19 <- min(data_WT19$WTLCCm, na.rm=TRUE)
minWTD19
meanWTD19 <- mean(data_WT19$WTLCCm, na.rm=TRUE)
meanWTD19
medianWTD19 <- median(data_WT19$WTLCCm, na.rm=TRUE)
medianWTD19
sdWTD19 <- sd(data_WT19$WTLCCm, na.rm=TRUE)
sdWTD19
# min, max, mean, median, sd 2020
maxWTD20 <- max(data_WT20$WTLCCm)
maxWTD20
minWTD20 <- min(data_WT20$WTLCCm)
minWTD20
meanWTD20 <- mean(data_WT20$WTLCCm)
meanWTD20
medianWTD20 <- median(data_WT20$WTLCCm)
medianWTD20
sdWTD20 <- sd(data_WT20$WTLCCm)
sdWTD20
# Check if WT data follows natural distribution
hist(data_WT19$WTLCCm)
hist(data_WT20$WTLCCm)
# Mann-Whitney U-test for 2020 and 2019 data
wilcox.test(data_WT19$WTLCCm, data_WT20$WTLCCm,
             alternative = "less",
             mu = 0, paired = FALSE, exact = TRUE, correct = TRUE,
             conf.int = TRUE, conf.level = 0.95)
# Read 101 WT data
data_10219 <- read.csv('/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data
plotting/102/102_2019_treated_with_logger_installation.csv',
                     header = TRUE, sep = ",", quote = "",
                     dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
data_10220 <- read.csv('/Users/lassi/Dropbox/1. Koulu/DI-työ/R prosessi/Data
plotting/102/102_2020_treated_with_logger_installation.csv',
                     header = TRUE, sep = ",", quote = "",
                     dec = ".", fill = TRUE, comment.char = "", skipNul=FALSE)
# Aggregate WTD at 101 into daily mean values into new dataset
data_10219$WTLCCm[data_10219$WTLCCm>1.45]<-NA # remove outliers outside logger measurement range
data_10219$Hours <- format(as.POSIXct(data_10219$Date.Time, "%d.%m.%Y %H:%M", tz = ""), format = "%H:%M:%S") #
Add time column
data_10219$date <- format(as.Date(data_10219$Date.Time, "%d.%m.%Y"), format = "%m/%d/%Y") # Add date column
data_10220$Hours <- format(as.POSIXct(data_10220$Date.Time, "%d.%m.%Y %H:%M", tz = ""), format = "%H:%M:%S") #
Add time column
data_10220$date <- format(as.Date(data_10220$Date.Time, "%d.%m.%Y"), format = "%m/%d/%Y") # Add date column
agWTD10219 <- aggregate(WTLCCm ~ date, data_10219, stat)
agWTD10220 <- aggregate(WTLCCm ~ date, data_10220, stat)
str(agWTD10219)
agWTD10219$date <- mdy(agWTD10219$date) # Change character into date
str(agWTD10220)
agWTD10220$date <- mdy(agWTD10220$date) # Change character into date
# Mann-Whitney U-test for 101 vs 103 2019
hist(data_10219$WTLCCm)

```

```

hist(data_WT19$WTLCcm)
wilcox.test(data_10219$WTLCcm, data_WT19$WTLCcm,
             alternative = "greater",
             mu = 0, paired = FALSE, exact = TRUE, correct = TRUE,
             conf.int = TRUE, conf.level = 0.95)
# Mann-Whitney U-test for 101 vs 103 2020
hist(data_10220$WTLCcm)
hist(data_WT20$WTLCcm)
wilcox.test(data_10220$WTLCcm, data_WT20$WTLCcm,
             alternative = "two.sided",
             mu = 0, paired = FALSE, exact = TRUE, correct = TRUE,
             conf.int = TRUE, conf.level = 0.95)
wilcox.test(data_10220$WTLCcm, data_WT20$WTLCcm,
             alternative = "greater",
             mu = 0, paired = FALSE, exact = TRUE, correct = TRUE,
             conf.int = TRUE, conf.level = 0.95)

# 2019
vect<-data_WT19$WTLCcm
vect<-vect[complete.cases(vect)]
sum(0<vect)/length(vect)*100 # % of time above ground (WTD>0cm)
(length(vect[vect > -20]) - length(vect[vect > 0]))/length(vect)*100 # % of time between 0...-20cm
sum(-20>vect)/length(vect)*100 # % of time below -20cm
# 2020
vect<-data_WT20$WTLCcm
sum(0<vect)/length(vect)*100 # % of time above ground (WTD>0cm)
(length(vect[vect > -20]) - length(vect[vect > 0]))/length(vect)*100 # % of time between 0...-20cm
sum(-20>vect)/length(vect)*100 # % of time below -20cm
# ----- PLOTTING -----
# Lineplot average WTD agWTD
avgWTD19 <- ggplot(agWTD19, aes(x=date, y=WTLCcm)) +
  geom_line() +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous( limits=c(-45, 10), breaks=seq(-45,20,5))+
  geom_hline(yintercept=0, linetype="dashed", color = "black")
avgWTD19
avgWTD20 <- ggplot(agWTD20, aes(x=date, y=WTLCcm)) +
  geom_line() +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous( limits=c(-20, 10), breaks=seq(-20,10,5))+
  geom_hline(yintercept=0, linetype="dashed", color = "black")
avgWTD20
# Boxplot average WTD agWTD
avgWTDbox19 <- ggplot(agWTD19, aes(y=WTLCcm)) +
  geom_boxplot(outlier.colour="black", outlier.shape=1,
              outlier.size=2, notch=FALSE)+
  theme_classic()+
  theme(axis.ticks.x = element_blank(), axis.text.x = element_blank()) +
  scale_y_continuous(name="WTD päiväkohtainen keskiarvo cm", limits=c(-45, 10), breaks=seq(-45,10,5))
avgWTDbox19
avgWTDbox20 <- ggplot(agWTD20, aes(y=WTLCcm)) +
  geom_boxplot(outlier.colour="black", outlier.shape=1,
              outlier.size=2, notch=FALSE)+
  theme_classic()+
  theme(axis.ticks.x = element_blank(), axis.text.x = element_blank()) +
  scale_y_continuous(name="WTD päiväkohtainen keskiarvo cm", limits=c(-20, 10), breaks=seq(-20,10,5))
avgWTDbox20
# Boxplot and lineplot side by side
avgWTDbox19+avgWTD19+plot_layout(widths = c(0.5, 5))
avgWTDbox20+avgWTD20+plot_layout(widths = c(0.5, 5))
# Full WTD dataset
# Lineplot full WTD dataset
fullWTD19 <- ggplot(data_WT19, aes(x=date, y=WTLCcm)) +
  geom_point(size=1, shape=1)+
  geom_line(size=0.4) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-45, 10), breaks=seq(-45,10,5))+
  geom_hline(yintercept=0, linetype="dashed", color = "black")
fullWTD19
fullWTD20 <- ggplot(data_WT20, aes(x=date, y=WTLCcm)) +
  geom_point(size=1, shape=1)+
  geom_line(size=0.4) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+

```

```

theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-20, 10), breaks=seq(-20,10,5))+
geom_hline(yintercept=0, linetype="dashed", color = "black")
fullWTD20
# Boxplot full WTD dataset
fullWTDbox19 <- ggplot(data_WT19, aes(y=WTLCCm)) +
  geom_boxplot(outlier.colour="black", outlier.shape=1,
    outlier.size=2, notch=FALSE)+
  theme_classic()+
  theme(axis.ticks.x = element_blank(), axis.text.x = element_blank()) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-45, 10), breaks=seq(-45,10,5))
fullWTDbox19
fullWTDbox20 <- ggplot(data_WT20, aes(y=WTLCCm)) +
  geom_boxplot(outlier.colour="black", outlier.shape=1,
    outlier.size=2, notch=FALSE)+
  theme_classic()+
  theme(axis.ticks.x = element_blank(), axis.text.x = element_blank()) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-20, 10), breaks=seq(-20,10,5))
fullWTDbox20
# Boxplot and lineplot side by side
fullWTDbox19+fullWTD19+plot_layout(widths = c(0.5, 5))
fullWTDbox20+fullWTD20+plot_layout(widths = c(0.5, 5))
# Air temperature from grid Tg
# Plot air temperature from grid subTg
Tg19 <- ggplot(subTg19, aes(x=date, y=Tout)) +
  geom_line() +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Ilman lämpötila degC", limits=c(-5, 25), breaks=seq(-5,25,5))
Tg19
# Precipitation from grid Pg
# Column plot precipitation from grid Pg
Pg19 <- ggplot(subPg19, aes(x=date, y=Pout)) +
  geom_col() +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d")+
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Sademäärä mm", limits=c(-0, 30), breaks=seq(0,30,2))
Pg19
Pg20 <- ggplot(subPg20, aes(x=date, y=Pout)) +
  geom_col() +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d")+
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Sademäärä mm", limits=c(-0, 30), breaks=seq(0,30,2))
Pg20
# Avg WTD, Tg & Pg in same chart
WTDavgPg19 <- ggplot() +
  geom_col(color="blue", data=subPg19, aes(x=date, y=Pout)) +
  geom_line(data=agWTD19, aes(x=date, y=WTLCCm)) +
  geom_line(data=subTg19, aes(x=date, y=Tout), linetype="dashed") +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(legend.position="top", axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
    axis.title.y.right = element_text(hjust=0.24),
    axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-45, 30), breaks=seq(-45,30,5),
    sec.axis=sec_axis(~., name="Sademäärä mm, ilman lämpötila degC", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
WTDavgPg19
WTDavgPg20 <- ggplot() +
  geom_col(color="blue", data=subPg20, aes(x=date, y=Pout)) +
  geom_line(data=agWTD20, aes(x=date, y=WTLCCm)) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(legend.position="top", axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
    axis.title.y.right = element_text(hjust=0.24),
    axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-20, 30), breaks=seq(-20,30,5),
    sec.axis=sec_axis(~., name="Sademäärä mm", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
WTDavgPg20
# WTD, Tg & Pg in same chart
WTDPg19 <- ggplot() +
  geom_col(color="blue", data=subPg19, aes(x=date, y=Pout)) +
  geom_line(data=data_WT19, aes(x=date, y=WTLCCm), size=0.3) +
  geom_point(data=data_WT19, aes(x=date, y=WTLCCm), size=1, shape=1)+
  geom_line(linetype="dashed", data=subTg19, aes(x=date, y=Tout)) +

```

```

scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
theme_classic()+
theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
      axis.title.y.right = element_text(hjust=0.24), legend.position="top",
      axis.title.y.left=element_text(hjust=0.15)) +
scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-45, 30), breaks=seq(-45,30,5),
                   sec.axis=sec_axis(~., name="Sademäärä mm, ilman lämpötila degC", breaks=seq(0,30,2)))+
geom_hline(yintercept=0, color = "black")
WTDp19
WTDp20 <- ggplot() +
  geom_col(color="blue", data=subPg20, aes(x=date, y=Pout)) +
  geom_line(data=data_WT20, aes(x=date, y=WTLcCm), size=0.3) +
  geom_point(data=data_WT20, aes(x=date, y=WTLcCm), size=1, shape=1)+
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.24), legend.position="top",
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-20, 30), breaks=seq(-20,30,5),
                     sec.axis=sec_axis(~., name="Sademäärä mm", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
WTDp20
# Precipitation from closest station Ps
# Column plot precipitation from closest station subPs
Ps19 <- ggplot() +
  geom_col(color="blue", data=subPs19, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs19, aes(x=date, y=Lumensyvyys_cm))+
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d")+
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Sademäärä mm, lumensyvyys cm", limits=c(-0, 30), breaks=seq(0,30,2))
Ps19
Ps20 <- ggplot() +
  geom_col(color="blue", data=subPs20, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs20, aes(x=date, y=Lumensyvyys_cm))+
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d")+
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous(name="Sademäärä mm, lumensyvyys cm", limits=c(-0, 30), breaks=seq(0,30,2))
Ps20
# Avg WTD & Ps in same chart
avgWTDps19 <- ggplot() +
  geom_col(color="blue", data=subPs19, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs19, aes(x=date, y=Lumensyvyys_cm))+
  geom_line(data=agWTD19, aes(x=date, y=WTLcCm)) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.25), legend.position="top",
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-45, 30), breaks=seq(-45,30,5),
                     sec.axis=sec_axis(~., name="Sademäärä mm, lumensyvyys cm", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
avgWTDps19
avgWTDps20 <- ggplot() +
  geom_col(color="blue", data=subPs20, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs20, aes(x=date, y=Lumensyvyys_cm))+
  geom_line(data=agWTD20, aes(x=date, y=WTLcCm)) +
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.25), legend.position="top",
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-20, 30), breaks=seq(-20,30,5),
                     sec.axis=sec_axis(~., name="Sademäärä mm, lumensyvyys cm", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
avgWTDps20
# WTD & Ps in same chart
WTDps19 <- ggplot() +
  geom_col(color="blue", data=subPs19, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs19, aes(x=date, y=Lumensyvyys_cm))+
  geom_line(data=data_WT19, aes(x=date, y=WTLcCm), size=0.3) +
  geom_point(data=data_WT19, aes(x=date, y=WTLcCm), size=1, shape=1)+
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.24), legend.position = "top",
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-45, 30), breaks=seq(-45,30,5),

```

```

sec.axis=sec_axis(~., name="Sademäärä mm, lumensyvyys cm", breaks=seq(0,30,2)))+
geom_hline(yintercept=0, color = "black")
WTDPs19
WTDPs20 <- ggplot() +
  geom_col(color="blue", data=subPs20, aes(x=date, y=Sademäärä_mm)) +
  geom_col(color="light blue", data=subSs20, aes(x=date, y=Lumensyvyys_cm))+
  geom_line(data=data_WT20, aes(x=date, y=WTLCcm), size=0.3) +
  geom_point(data=data_WT20, aes(x=date, y=WTLCcm), size=1, shape=1)+
  scale_x_date(date_breaks = "1 week", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title.x = element_blank(), axis.text.x=element_text(angle=60, hjust=1),
        axis.title.y.right = element_text(hjust=0.24), legend.position = "top",
        axis.title.y.left=element_text(hjust=0.15)) +
  scale_y_continuous(name="Vedenpinnan syvyys WTD cm", limits=c(-20, 30), breaks=seq(-20,30,5),
                    sec.axis=sec_axis(~., name="Sademäärä mm, lumensyvyys cm", breaks=seq(0,30,2)))+
  geom_hline(yintercept=0, color = "black")
WTDPs20
# Daily average WTD at 102 and 104 at same graph for the whole study period
colors<-c("102"="black", "104"="blue")
avgWTDall <- ggplot() +
  geom_line(data=agWTD19, aes(x=date, y=WTLCcm, color="104")) +
  geom_line(data=agWTD20, aes(x=date, y=WTLCcm, color="104")) +
  geom_line(data=agWTD10219, aes(x=date, y=WTLCcm, color="102")) +
  geom_line(data=agWTD10220, aes(x=date, y=WTLCcm, color="102")) +
  scale_x_date(date_breaks = "1 month", date_labels = "%Y %b %d") +
  theme_classic()+
  theme(axis.title = element_blank(), legend.title=element_blank(),
        legend.position="top", axis.text.x=element_text(angle=60, hjust=1)) +
  scale_y_continuous( limits=c(-45, 10), breaks=seq(-45,20,5)) +
  geom_hline(yintercept=0, linetype="dashed", color = "black") +
  scale_color_manual(values = colors)
avgWTDall

```